Störeffektunterdrückung in 2D-Messdaten mittels DiscoGAN

Sarah Johannesmann[1], Dimitri Springer[1], Christian Thiel[2], Bernd Henning[1]
[1] *Elektrische Messtechnik, Universität Paderborn, 33098 Paderborn, Deutschland,*
Email: johannesmann@emt.uni-paderborn.de
[2] *Benteler Stahl/Rohr, Paderborn, 33104 Paderborn, Deutschland*

Einleitung

Ultraschallbasierte Messverfahren eignen sich für die zerstörungsfreie Materialcharakterisierung. Je nach Messverfahren werden Schallgeschwindigkeiten aus 1D- oder 2D-Messdaten geschätzt. In dem hier verwendeten Messverfahren ergeben sich 2D-Messmatrizen, in denen die ausbreitungsfähigen Moden als Grate sichtbar werden. Aufgrund ihrer Ähnlichkeit zu Dispersionsdiagrammen werden solche Messmatrizen im Folgenden auch Dispersionsabbildungen genannt. Zur automatisierten Schallgeschwindigkeitsbestimmung müssen die Grate möglichst ohne zusätzliche Interaktionen extrahiert werden. Neuronale Netze finden in der Bilderkennung große Anwendung, benötigen jedoch eine große Anzahl an Trainingsdaten. Da die Anzahl an Trainingsdaten jedoch begrenzt ist, wird in diesem Beitrag ein DiscoGAN, welches mit vergleichsweise wenigen Trainingsdaten auskommt, zur Lokalisation der Grate genutzt.

Messtechnische Erfassung

Das in Abbildung 1 dargestellte Messsystem wird zur Detektion von Lamb-Wellen [1] in plattenförmigen Proben eingesetzt. Für eine breitbandige Anregung der Probenplatte werden kurze Laserpulse von 3 ns linienförmig auf die Probenplatte fokussiert. Die Fokussiereinheit bestehend aus Oberflächenspiegel und Zylinderlinse befindet sich auf einer Linearachse, um die Fokussiereinheit in äquidistanten Abständen zum empfangenden Ultraschallwandler zu verfahren.

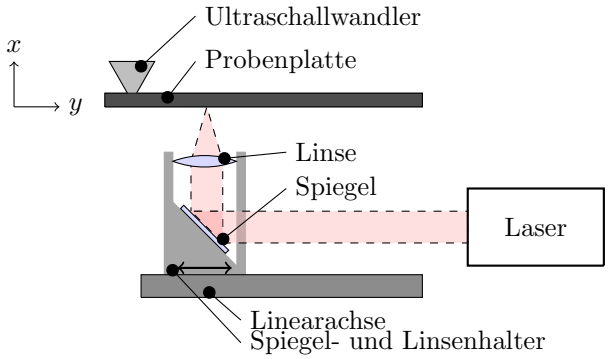

Abbildung 1: Schematische Darstellung des Messsystems nach [2].

Wird nun nacheinander an verschiedenen Positionen angeregt und jeweils die empfangenden Signale aufgezeichnet, ergibt sich eine zeit- und ortsabhängige Signalmatrix. Mittels zweidimensionaler Fouriertransformation wird die zeit-/ortsabhängige Matrix in eine frequenz- und wellenzahlabhängige Matrix (Dispersionsabbildung) überführt, in der die sichtbaren Grate die ausbreitungsfähigen Moden repräsentieren [3].

Definition von Störeffekten

Sollen die einzelnen Grate aus der Abbildung extrahiert werden z.B. zur Bestimmung von Gruppengeschwindigkeiten, Materialparameterbestimmung oder ähnliches, sind möglichst eindeutig abgegrenzte und kontinuierliche Grate erstrebenswert, sodass Matrixwerte, an denen Grate liegen, möglichst gegen große Werte streben sollten, Werte außerhalb der Grate gegen Null. Daher wird hier der Begriff Störeffekte als Sammelbegriff für alle Effekte, die zu Abweichungen von einem idealen Dispersionsdiagramm führen, benutzt. Der Signal-Rausch-Abstand (SNR) wird in der Regel durch Mittelungen mehrerer Messungen an jeder Anregungsposition erhöht. Zum einen ergeben sich Störeffekte aus der Messung selbst aufgrund von Einkopplung von Störsignalen oder aufgrund von Inhomogenitäten der Probe, weil z.B. die Plattendicke schwankt, aber auch auftretende Effekte resultierend aus den angewandten Signalverarbeitungsschritten [4]. Diese werden zwar angewandt, um Störungen zu vermeiden, können aber bei falscher Parametrisierung ebenfalls zu Störeffekten führen. So kann eine zeitliche Fensterung zur Unterdrückung von Reflexionen vom Rand der Probe und Vermeidung des Leackage-Effekts führen, bei Verwendung eines zu schmalen Fensters jedoch auch zu Informationsverlust. Die Verwendung der ideal geeigneten Fensterfunktion ist somit abhängig von den Wellenlaufzeiten in der jeweiligen Probe. Zum anderen treten aber auch physikalische Effekte auf, die keine Störeffekte im eigentlichen Sinn entsprechen, wie die Begrenzung der Wellenzahl aufgrund der geometrischen Abmessungen des Empfangswandlers oder die begrenzte Anregung von Moden bzw. Frequenz-/Wellenzahlbereiche, bei denen die Out-of-plane Auslenkung an der Oberfläche zu Null wird, sodass diese nicht gemessen werden, was zu Unterbrechungen in den Graten führt. Beispielsweise ist es charakteristisch, dass sich A0- und S0-Moden in der Dispersionsabbildung auslöschen, sobald sie zusammenlaufen oder sich kreuzen, da auch dort die Out-of-plane-Auslenkung verschwindet. Bei Polymerproben führt deren Viskoelastizität zudem zu einer frequenzabhängigen Schallschwächung. Abbildung 2 zeigt exemplarisch eine Dispersionsabbildung einer Polycarbonat-Probe unter einer mechanischen Vorspannung [5]. Um den Einfluss von Materialrelaxationen in der Probe gering zu halten, ist die Anzahl der Signalmittelungen je Messposition zur SNR-Erhöhung begrenzt, gleich-

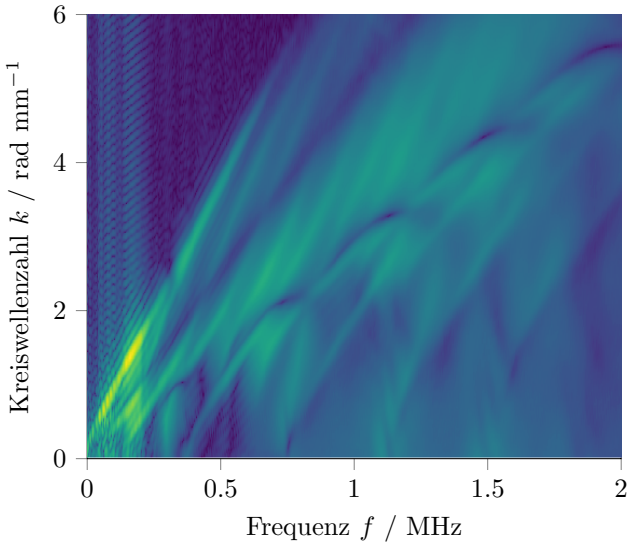

Abbildung 2: Dispersionsabbildung einer Polycarbonat-Probe, gemessen unter einer mechanischen Vorspannung von $\sigma = 34{,}55\,\mathrm{MPa}$ [5].

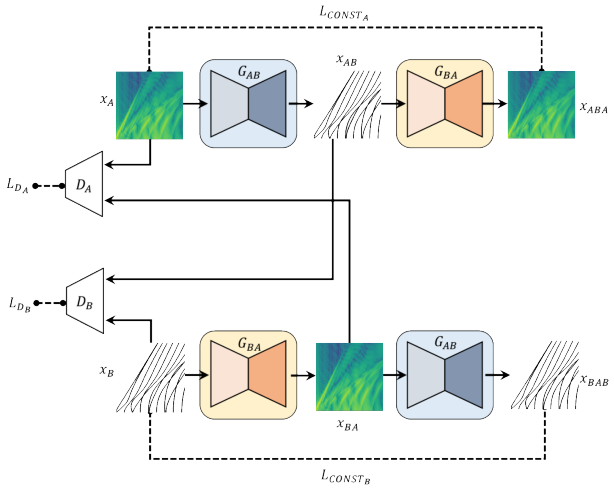

Abbildung 3: Architektur des DiscoGAN nach [7]

zeitig wird die Messung aber auch von sich ändernden Materialeigenschaften beeinflusst. Daraus ergibt sich ein schwacher Kontrast im Bereich der ausbreitungsfähigen Moden, sodass diese schwerer extrahiert werden können. Dem kann beispielsweise Abhilfe durch spaltenweise Normierung oder Festlegen einer unteren Grenze im Wertebereich geschaffen werden, verstärkt jedoch auch eventuell vorhandene Störsignale oder führt zum Verschwinden von Graten. Um den Prozess zu automatisieren und somit nicht im Einzelfall über die Anwendung eines jeden Signalverarbeitungsschrittes und dessen Parametrisierung entscheiden zu müssen, wird ein neuronales Netz trainiert, das zunächst auf unverarbeiteten Dispersionsabbildungen trainiert wird, um die Grate der ausbreitungsfähigen Moden zu extrahieren.

Trainingsdatensatz

Der Trainingsdatensatz besteht zunächst aus dem Betrag der messtechnisch erzeugten, auf den Maximalwert normierten Signalmatrix im Frequenz-/Wellenzahlbereich. Durch Herunterabtasten im Zeitbereich, sodass der Frequenzbereich bis 2 MHz erhalten bleibt, und Zeropadding im Orts- sowie teilweise im Zeitbereich wird die Messmatrix auf eine einheitliche Größe von 512×512 Werte gebracht. Um die Lage der Moden für das Training zu kennen, werden Dispersionsdiagramme mittels semi-analytischer Finite Elemente Simulation (SAFE) [6] erzeugt. Dazu sind zuvor die Materialparameter der Probe im inversen Verfahren nach [4] identifiziert worden. Das Identifikationsverfahren benötigt Startwerte, die aus den Graten in der Dispersionsabbildung geschätzt werden, jedoch ist für die darauffolgende Parameteroptimierung keine explizite Extraktion der Moden erforderlich [4]. Die Werte der berechneten Dispersionsdiagramme werden in eine Matrix mit ebenfalls 512×512 Werten geschrieben: An den berechneten Frequenz-/Wellenzahlpaaren, wird der entsprechende Matrixwert auf Eins, an allen anderen auf Null gesetzt. Die somit aus berechneten Dispersionsdiagrammen erzeugten Matrizen werden während des Trainings mit den Messmatrizen verglichen. Insgesamt sind 143 Messungen an größtenteils polymeren Proben vorhanden. Davon werden 70% als Trainingsdaten und jeweils 15% als Test- und Validierungsdaten verwendet. Die Trainingsdaten werden während des Trainings in Stapel (Batches) von 2 bis 8 Matrizen aufgeteilt.

Netzarchitektur

Als Netzarchitektur wird ein *Discover Cross domain relations Generative adverserial network* (DiscoGAN) [7], wie in Abbildung 3 dargestellt, eingesetzt. Dies hat zum einen den Vorteil, dass es mit einem vergleichsweise kleinen Trainingsdatensatz auskommt, zum anderen kann es bidirektional genutzt werden, sodass nicht nur Störeffekte unterdrückt, sondern auch störbehaftete Dispersionsabbildungen aus berechneten Dispersionsdiagrammen erzeugt werden können, um z.B. Effekte wie Inhomogenitäten oder andere Messartefakte abzuschätzen. Prinzipiell besteht ein GAN aus zwei neuronalen Netzen: Einem Generator und einem Diskriminator. Der Generator verfolgt das Ziel Daten zu erzeugen, die nicht von den Trainingsdaten unterschieden werden können. Der Diskriminator hingegen versucht zu unterscheiden, ob der Datensatz echt oder vom Generator erzeugt worden ist [8]. Bei DiscoGANs wie in Abbildung 3 handelt es sich um eine Erweiterung mit einem zweiten GAN mit dem Ziel domänenübergreifende Beziehungen zu lernen, sodass der Stil einer Domäne auf eine andere unter Beibehaltung der ursprünglichen Struktur adaptiert wird. Es besteht aus zwei analog aufgebauten einzelnen GANs (obere bzw. untere Teil in Abbildung 3), die simultan trainiert werden. Jedes einzelne GAN besteht wiederum aus jeweils zwei Generatoren G_{AB} und G_{BA} sowie einem Diskriminator (D_A für das obere GAN, D_B für das untere GAN). Der Generator G_{BA} hat in beiden GANs die Aufgabe Matrizen aus der störungsfreien Domäne B in den Raum der störbehafteten Messdaten A zu übertragen, der Generator G_{AB} hingegen transformiert die Daten aus der störbehafteten Domäne A in den störungsfreien Raum B. Die Diskriminatoren bewerten, ob

es sich um echte Daten oder von den Generatoren erzeugte Daten handelt: Während D_A bewertet, ob es sich um einen echten Messdatensatz oder vom Generator G_{BA} aus Simulationsdaten erzeugte Daten handelt, bewertet der Diskriminator D_B, ob es sich um Simulationsdaten oder um von G_{AB} aus der Domäne der Messdaten transformierte Daten handelt. Nach zweimaliger Transformation durch die Generatoren G_{AB} und G_{BA} ergeben sich durch die Diskrepanz zwischen Eingangs- und Ausgangsdaten die Rekonstruktionsfehler L_{CONST_A} und L_{CONST_B}.

Struktur der Einzelkomponenten

Da sowohl Eingangs- und Ausgangsdaten in beiden Domänen gleiche Dimensionen besitzen, weisen die Generatoren eine Struktur ähnlich eines Autoencoders auf. Prinzipiell orientiert sich der Aufbau an [7]. Der quasi Encoderteil der Generatoren besteht aus fünf Faltungsschichten, die jeweils eine Filtergröße von 4×4 Werten mit einer Schrittweite von Zwei enthalten. Die Anzahl der Filter pro Schicht ist Tabelle 1 zu entnehmen. Am Eingang des Encoders des Generators befindet sich eine zusätzliche Faltungsschicht mit einer Schrittweite von Eins, sodass insgesamt im Encoderteil die Eingangsdaten von 512×512 auf 16×16 Werten reduziert werden. Der Decoder ist invers zum Encoder aus transponierten Faltungsschichten aufgebaut. Die Residuen der Faltungsschichten im Encoderteil werden zu den jeweiligen transponierten Faltungsschichten im Decoderteil geführt [9]. Der Diskriminator ist identisch zum Encoder des Generators aufgebaut.

Parameter des GANs

Um schwindene Gradienten während des Trainings vorzubeugen wird die SELU (*Scaled Exponential Linear Unit*)

$$s(x) = \lambda_s \begin{cases} x & \text{für } x > 0 \\ \alpha(e^x - \alpha) & \text{sonst} \end{cases} \quad (1)$$

mit den Parametern $\alpha = 1{,}6733$, $\lambda_s = 1{,}0507$ nach [10] als Aktivierungsfunktion verwendet, in der Ausgangsschicht hingegen der $\tanh(x)$, damit die Ausgangsdaten im Wertebereich von $[-1, 1]$ liegen. Als Kostenfunktion verwenden die Diskriminatoren D_A und D_B den die mittlere quadratische Abweichung (MSE), die Generatoren die mittlere absolute Abweichung (MAE). Zudem wird zur Vermeidung einer Überanpassung des Netzes eine L2-Regularisierung verwendet, sodass sich aus der ursprünglichen Kostenfunktion L die jeweils angepasste

$$\tilde{L} = L + \frac{\lambda}{2} \sum_j |w_j|^2 \quad (2)$$

mit den Netzgewichten w_j und dem Regularisierungsparameter λ, der hier zu $\lambda = 0{,}0001$ gewählt wird, ergibt [11].

Ergebnisse

Die Hyperparameter wie Lernrate des Optimierers, Anzahl der Filtermasken pro Schicht, Filtergröße pro Schicht, Regularisierungsparameter λ (vgl. Glg. (2)) werden empirisch bestimmt, wobei das Netz 100 Epochen trainiert und die erkannten Grate sowie die entsprechenden Werte der Kostenfunktionen miteinander verglichen werden. Die niedrigsten Kosten ergeben sich für die in Tabelle 1 angegebenen Parameter.

Tabelle 1: Parameter des DiscoGANs

Lernrate		0,0002
Batch-Größe		8
Filtergröße je Schicht		4×4
#Filtermasken je Layer im Encoder	**1**	16
	2	32
	3	64
	4	128
	5	256
	6	256

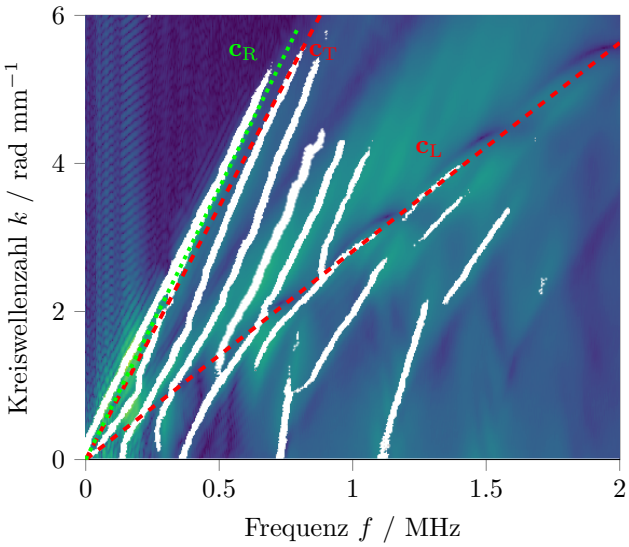

Abbildung 4: Extrahierte Grate einer Polycarbonat-Messung (Abbildung 2) unter einer mechanischen Vorspannung von $\sigma = 34{,}55\,\text{MPa}$

Bei Anwendung der Transformation auf Messdaten aus dem Testdatensatz wie z.B. die Messung einer 3 mm dicken Polycarbonat-Platte (Abbildung 2) oder einer 3 mm dicken PMMA-Probe (Abbildung 5) ergeben sich die jeweils in Abbildung 4 und 6 dargestellten erkannten Grate. Das in Abbildung 2 dargestellte Messergebnis weist einen sehr schwachen Kontrast der ausbreitungsfähigen Moden zum Hintergrund der Abbildung auf, was dazu führt, dass nur ein Teil der Grate erkannt wird (Abbildung 4). Insbesondere die Grate bei hohen Kreiswellenzahlen werden hier nicht erkannt.

Weist die Messmatrix einen größeren Kontrast wie beispielsweise im Fall einer Messung an einer Polymethylmethacrylat (PMMA)-Probe (Abbildung 5) auf, werden quasi alle Moden erkannt (vgl. Abbildung 6), selbst sehr schwach auftretende Moden (gelbes Rechteck in Abbildung 6) werden teilweise erkannt. Lediglich eine in der Messung erkennbare Mode (rotes Rechteck in Abbildung 6) wird nicht erkannt. Da in der Messung nicht alle Moden gleich stark angeregt werden bzw. nicht alle (Teil-)Moden eine messbare Out-of-plane Auslenkung

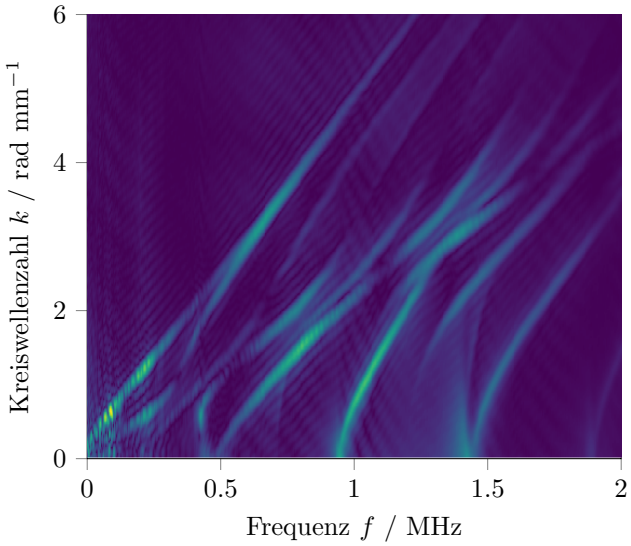

Abbildung 5: Dispersionsabbildung einer Polymethylmethacrylat (PMMA)-Probe.

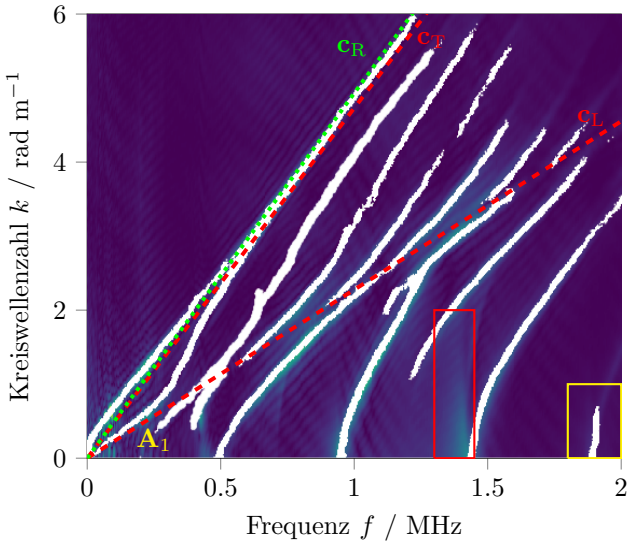

Abbildung 6: Aus der in Abbildung 5 dargestellten Dispersionsabbildung erkannten Grate.

aufweisen, treten in den Messdaten Unterbrechungen in den Graten der propagierenden Moden auf. Diese werden von dem Netz zum Teil interpoliert, wie bei PMMA am Beispiel der A1-Mode erkennbar ist.

Zusammenfassung und Ausblick

Es wird ein DiscoGAN zur Lokalisation der Grate in Messdaten, in denen die propagierenden Moden als Grate sichtbar werden, verwendet. Trotz starker Hintergrundstörungen werden Grate erkannt. Um die Datenbasis zu erweitern, kann die Datenbasis durch FEM-Simulationen, insbesondere nicht-isotroper Proben, ergänzt werden. Da das GAN besser auf Daten mit hohem Kontrast arbeitet, könnten die Messergebnisse weiter vorverarbeitet werden. Große Verbesserungen ergeben sich z.B. durch Zeropadding [4], allerdings ist die Größe der Eingangsdaten für das neuronale Netz beschränkt, sodass abgewägt werden muss, ob es vorteilhafter ist, die Messmatrix für das Netz zu verkleinern oder das Netz möglicherweise bei entsprechender Verarbeitung noch benötigt wird. Kontinuierliches Training mit neuen Messdaten verbessert allerdings auch die Bilderkennung mittels neuronalem Netz. Da das DiscoGAN bidirektionale Abbildungen lernt, können ebenfalls synthetische, den Messdaten ähnliche Matrizen aus berechneten Dispersionsdiagrammen transformiert werden, sodass bei entsprechendem Training Einflüsse von Messartefakten prädiziert werden können.

Literatur

[1] H. Lamb, „On Waves in an Elastic Plate“, *Proceedings of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*, Bd. 93, Nr. 648, S. 114–128, 1917.

[2] L. Claes, T. Meyer, F. Bause, J. Rautenberg und B. Henning, „Determination of the material properties of polymers using laser-generated broadband ultrasound“, *JSSS*, Bd. 5, Nr. 1, S. 187–196, 2016.

[3] D. Alleyne und P. Cawley, „A 2-dimensional Fourier transform method for the quantitative measurement of Lamb modes“, in *IEEE Symposium on Ultrasonics*, 1990.

[4] S. Johannesmann, L. Claes, M. Webersen und B. Henning, „Inverser Ansatz zur akustischen Charakterisierung plattenförmiger Materialproben“, in *Fortschritte der Akustik*, 2017.

[5] S. Johannesmann, T. Brockschmidt, F. Rump, M. Webersen, L. Claes und B. Henning, „Acoustic material characterization of prestressed, plate-shaped specimens“, in *Sensoren und Messsysteme*, VDE Verlag GmbH, 2018, S. 231–234.

[6] I. Bartoli, A. Marzani, F. Di Lanza Scalea und E. Viola, „Modeling wave propagation in damped waveguides of arbitrary cross-section“, *Journal of Sound and Vibration*, Bd. 295, Nr. 3-5, 2006.

[7] T. Kim, M. Cha, H. Kim, J. K. Lee und Kim Jiwon, „Learning to discover cross-domain relations with generative adversarial networks“,

[8] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville und Y. Bengio, „Generative adversarial nets“, in *Advances in Neural Information Processing Systems 27*, Z. Ghahramani, M. Welling, C. Cortes, N. D. Lawrence und K. Q. Weinberger, Hrsg., Curran Associates, Inc., 2014, S. 2672–2680.

[9] K. He, X. Zhang, S. Ren und J. Sun, „Deep residual learning for image recognition“, IEEE Conference on Computer Vision and Pattern Recognition, Hrsg., IEEE, 2016, S. 770–778.

[10] G. Klambauer, T. Unterthiner, A. Mayr und S. Hochreiter, „Self-normalizing neural networks“, in *Advances in Neural Information Processing Systems 30*, Curran Associates, Inc., 2017, S. 971–980.

[11] C. M. Bishop, *Pattern recognition and machine learning*. New York, NY : Springer, 2009, ISBN: 978-0-387-31073-2, 0-387-31073-8.