

NEUARTIGER ANSATZ ZUR BESTIMMUNG VON TOTALDRUCKVERLUSTEN UND UMLENKUNG UNTER BENUTZUNG VON ERSATZMODELLEN

Andreas Schmitz, Marcel Aulich und Eberhard Nicke
Deutsches Zentrum für Luft- und Raumfahrt
Institut für Antriebstechnik
Abteilung Fan und Verdichter
51147 Köln, Deutschland
andreas.schmitz@dlr.de marcel.aulich@dlr.de eberhard.nicke@dlr.de

Zusammenfassung

Ein- und zweidimensionale Vorauslegungsverfahren sind nach wie vor ein wichtiges Werkzeug für die Auslegung von modernen Verdichtern.

Für deren Genauigkeit ist die Bestimmung von Minderumlenkung und Totaldruckverlusten von großer Bedeutung. Bisher wurden in den meisten Vorauslegungsverfahren empirische Korrelationen benutzt, um Minderumlenkung und Totaldruckverluste zu bestimmen.

Diese empirischen Korrelationen decken in der Regel nur den Bereich von Profilgeometrien ab, für den sie konzipiert worden sind. Zudem ist die Bestimmung der Umlenkung und der Verluste (im Weiteren Profilperformance) bei hohen Anströmmachzahlen und im Off-Design oftmals ungenau.

Heutzutage wird ein neuer Ansatz benötigt, welcher in der Lage ist, die Profilperformance von komplexen Geometrien mit einer hohen Anzahl von Geometrieparametern zu bestimmen und die auch im Off-Design.

Eine neue Methodik, welche diese Anforderungen erfüllt, soll im Folgenden vorgestellt werden.

Diese Methodik nutzt eine sehr große Profildatenbank in Verbindung mit Ersatzmodellen, um die Profilperformance mit hoher Genauigkeit zu bestimmen und wurde im Rahmen des DLR internen Projekts EVITA (Evaluierung innovativer Turbo-Antriebe) entwickelt.

Begonnen wurden die ersten Untersuchungen mit einer Datenbank aus ca. 10^6 zufällig generierten Profilgeometrien mit zufällig generierten Anströmbedingungen. Zu jeder Profilgeometrie mit Anströmbedingungen wird zusätzlich die dazugehörige Strömungslösung mit dem 2D-Euler-Grenzschichtverfahren MISES erzeugt und gespeichert.

Die Profilgeometrie wird in dieser Datenbank durch 10 Geometrieparameter (z.B. Staffelungswinkel, Sehnenlänge etc.) und 4 Anströmbedingungen (Anströmmachzahl, Anströmwinkel, MVDR, Reynoldszahl) beschrieben. Es konnte mit diesen Randbedingungen bereits ein Machzahlbereich von 0,3 bis 1,3 abgedeckt werden. Mit der hier vorgestellten Vorgehensweise, kann das Modell leicht hinsichtlich Parameteranzahl, Wertebereiche der Parameter und Genauigkeit beliebig erweitert werden.

Neuronale Netzwerke wurden mit der bereits erwähnten Datenbank trainiert, um den funktionalen Zusammenhang zwischen Geometrie/Anströmbedingungen und der Profilperformance herzustellen. Diese Neuronale Netzwerke dienen als Ersatzmodell für die für Vorauslegungsverfahren notwendigen Korrelationen.

Zudem wurde die Topologie der Ersatzmodelle optimiert, um ein bestmögliches Ergebnis zu erzielen. Diese Ersatzmodelle wurden in das Vorauslegungstool ACDC (Advanced Compressor Design Code) eingebettet, welches zur Vorauslegung und Nachrechnung von Verdichtern im DLR eingesetzt wird. Insbesondere wird das Tool im Rahmen des DLR internen Projekts EVITA zur Verdichterauslegung verwendet und mit anderen Triebwerksauslegungsverfahren gekoppelt.

Um diese neue Methodik zu validieren, wurde der erste Rotor eines 4-stufigen transsonischen Verdichters berechnet. Zusätzlich wurde eine Profilloptimierung unter Benutzung der Ersatzmodelle durchgeführt und im Folgenden präsentiert.

1. NOMENKLATUR

| | |
|-----------|---|
| \dot{m} | Massenstrom |
| ρ | Dichte |
| p | Druck |
| ACDC | Advanced Compressor Design Code, Vorauslegungstool entwickelt im DLR Institut für Antriebstechnik |
| β | Strömungswinkel |
| MVDR | Meridionales Stromdichteverhältnis $= \frac{\rho_2 V_{m2}}{\rho_1 V_{m1}}$ |
| m | Meridional |
| s | Entropie |
| T | Temperatur |
| V | Geschwindigkeit |
| x | Axiale Richtung |
| ω | Totaldruckverlust |

2. EINLEITUNG

Für das Design moderner, hochbelasteter und effizienter Kompressoren sind 3D Navier-Stokes Methoden heutzutage unverzichtbar. Allerdings sind diese Methoden sehr zeitaufwändig und benötigen eine detaillierte 3D-Geometrie. Deshalb eignet sich das 3D-Design nicht für die konzeptionelle Phase der Kompressorauslegung. Die Design-Suite ACDC wurde am DLR-Institut für Antriebstechnik entwickelt und beinhaltet ein 0D-, 1D- und 2D-Design-Tool. Eine der größten Schwierigkeiten bei 0D-, 1D- und 2D-Auslegungsverfahren ist die Vorhersage der Minderumlenkung und Totaldruckverluste von Verdichterprofilen. Bisher wurden meistens empirische Korrelationen für die Vorhersage dieser Profilperformance verwendet. Diese empirischen Korrelationen besitzen nur Gültigkeit für den Bereich von Profilgeometrien für den sie entwickelt worden sind. Darüber hinaus ist die Vorhersage der Profilperformance bei hohen Mach-Zahlen und im Off-Design meist ungenau. Einen guten Überblick über einige empirische Korrelationen bietet ÇETIN et al. [4]. Heutzutage ist ein neuer Ansatz erforderlich, der in der Lage ist, die Profilperformance von stark individualisierten

und hochbelasteten Profilgeometrien mit einer hohen Anzahl von Geometrieparametern vorherzusagen. In [12] Mönig et al. wurde empfohlen, einen Ansatz basierend auf einer Profildatenbank zu verwenden. In der folgenden Arbeit wird ein neuartiger Ansatz zur Vorhersage der Profilperformance vorgestellt, welcher auf einer sehr großen Profildatenbank basiert. Diese Profildatenbank wurde weitergehend verwendet, um Ersatzmodelle zu trainieren, welche die Profilperformance mit hoher Genauigkeit und Flexibilität vorhersagen können.

3. VORAUSLEGUNGSVERFAHREN ACDC

Das Vorauslegungsverfahren ACDC (Advanced Compressor Design Code) wird am DLR Institut für Antriebstechnik im Rahmen des Projektes EVITA (Evaluierung innovativer Turbo-Antriebe) entwickelt. Es beinhaltet ein 0D und 1D Mittelschnitt-Auslegungsverfahren und ein 2D-Stromlinienkrümmungsverfahren. In allen Verfahren werden die Profile aerodynamisch als Totaldruckverlust ω und Umlenkung $\Delta\beta$ dargestellt. Die Vorhersage der Profilperformance hat einen sehr hohen Einfluss auf die Güte der Strömungslösung.

$$(1) \quad \omega = \frac{p_{t1} - p_{t2}}{p_{t1} - p_2}$$

$$(2) \quad \Delta\beta = \beta_2 - \beta_1$$

3.1. 2D-Stromlinienkrümmungsverfahren

Das Stromlinienkrümmungsverfahren, welches in dieser Arbeit verwendet wird, basiert auf der Methode von Denton [6]. Das radiale Mischungsmodell basiert auf Mönig et al. [12] und Gallimore [8]. Der Code ist in C++ geschrieben und Thread parallelisiert [13].

Zudem werden folgende Annahmen über die Strömung getroffen:

- Adiabat
- Stetig
- Axialsymmetrisch
- Kompressibel
- Axial Machzahl < 1

Zusätzlich sind folgende Modelle im Code enthalten:

- Turbulente Mischung
- Endwand Grenzschicht
- Spalt Modell

4. NEUARTIGER ANSATZ ZUR BESTIMMUNG VON TOTALDRUCKVERLUSTEN UND UMLENKUNG

Die Vorhersage der Totaldruckverluste und der Umlenkung für eine gegebene Profilgeometrie mit einem bestimmten Strömungszustand ist ein großes Problem in der Vorausslegung. Daher wird eine funktionale Beziehung zwischen der Profilperformance und der Geometrie / Strömungszustand benötigt. Ein neuer Ansatz mit der Möglichkeit mehr Strömungs- und Geometrieparameter zu verwenden als mit empirischen Korrelationen und dies ohne einen Verlust an Stabilität und Geschwindigkeit, ist die Verwendung von Ersatzmodellen. BILD 1 zeigt den funktionalen Zusammenhang, welcher durch die Ersatzmodelle zur Vorhersage der Profilperformance beschrieben wird.

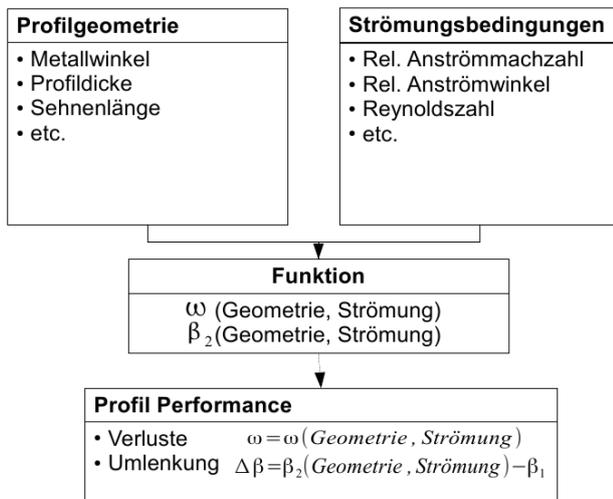


BILD 1. Funktionaler Zusammenhang zur Bestimmung von Totaldruckverlusten und Umlenkung einer Profilgeometrie

Der Input besteht auf der einen Seite aus der Profilgeometrie und auf der anderen Seite aus dem Strömungszustand. Der Output des Ersatzmodells ist der Abströmwinkel und die Totaldruckverluste. Die Ersatzmodelle sind also als Antwortflächen für die Vorhersage von Totaldruckverlusten $\omega(\text{Geometrie}, \text{Strömung})$ und Umlenkung $\beta_2(\text{Geometrie}, \text{Strömung}) - \beta_1$.

Einer der wichtigsten Vorteile von Ersatzmodellen ist die Fähigkeit der Generalisierung. Generalisierung beschreibt die Möglichkeit, Beziehungen in vorhandenen Daten finden zu können und Schlussfolgerungen für andere unbekannte Daten zu ziehen.

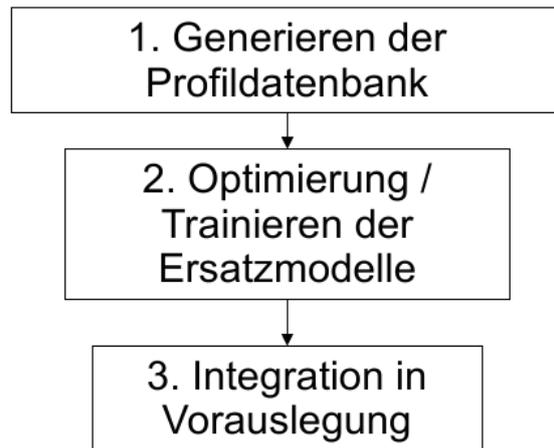


BILD 2. Notwendiger Prozess zur Benutzung der Ersatzmodelle

Der notwendige Prozess zur Implementierung der Ersatzmodelle ist in BILD 2 beschrieben und besteht aus drei grundlegenden Schritten.

1. Erstellung einer Profildatenbank mit zufälligen Mustern. Ein Muster besteht in diesem Fall aus 10 Geometrieparametern, 4 Strömungsparametern und 2 Profilperformance Parametern. MISES [5] wurde als Strömungslöser für die Berechnung der verwendeten Profilperformance Parameter verwendet. Das Framework zum Erstellen der zufälligen Profilgeometrien mit Strömungslösung für die Profildatenbank ist das Optimierungs-Tool AutoOpti [14, 2], welches am Institut für Antriebstechnik entwickelt wird.
2. Der zweite Schritt ist das Training und die Optimierung der Ersatzmodelle. Es wird eine Topologieoptimierung der Ersatzmodelle vorgenommen, um den Vorhersagefehler der Modelle zu minimieren [2].
3. Der dritte Schritt ist die Integration der trainierten Ersatzmodelle in das jeweilige Vorausslegungsverfahren. In dieser Arbeit werden zwei verschiedene Möglichkeiten gezeigt, die Ersatzmodelle zu verwenden. Das erste Beispiel ist die Integration in ein 2D-Throughflow-Programm und eine dazugehörige Nachrechnung eines vorhandenen Verdichters. Das zweite Beispiel ist die Nutzung der Ersatzmodelle, um zu einem gegebenen Strömungszustand eine möglichst optimale Profilgeometrie zu finden; also eine Optimierung auf den Ersatzmodellen.

5. GENERIEREN DER PROFILDATENBANK

Die Profildatenbank besteht aus ca. 10^6 zufällig erstellten Mustern. Jedes Muster in der Datenbank wird durch 14 Eingangsparameter und 2 Ausgangsparameter beschrieben (0).

| Eingabe | | Ausgabe |
|--------------------|---------------------------|-----------|
| Strömungsparameter | Geometrieparameter | |
| M_1 | β_{LE} | ω |
| β_1 | β_{TE} | β_2 |
| Reynoldszahl | β_{ST} | |
| MVDR | $\frac{C}{t}$ | |
| | $\frac{d_{max}}{C}$ | |
| | $\frac{d_{maxX}}{C}$ | |
| | x_{DeBoor} / y_{DeBoor} | |
| | r_{LE} | |
| | $AtoB$ | |

TAB 1. Ein- und Ausgabeparameter eines Musters aus der Profildatenbank

Die geometrische Parametrisierung, welche in dieser Arbeit verwendet worden ist, wird in 0 und BILD 3 beschrieben.

- β_{LE} und β_{TE} beschreiben die Metall-Winkel an der Vorder- und Hinterkante des Profils
- β_{ST} beschreibt den Staffelungswinkel des Profils (BILD 3)
- C ist die Sehnenlänge des Profils (BILD 3)

- t ist die Teilung des Profilhitters
- $\frac{d_{max}}{C}$ ist die relative maximale Dicke des Profils
- $\frac{d_{maxX}}{C}$ ist die relative axiale Lage der maximalen Dicke
- x_{DeBoor} / y_{DeBoor} beschreibt einen Spline-Kontrollpunkt auf der Saugseite des Profils
- r_{LE} ist der Vorderkantenradius
- $AtoB$ ist das Halbachsenverhältnis der Vorderkante

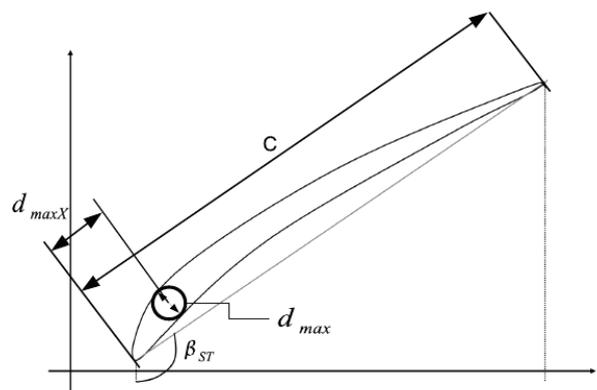


BILD 3. Profilparameter

Eine detailliertere Beschreibung kann in [14] gefunden werden. Um einen funktionalen Zusammenhang in einem 14-dimensionalen Parameterraum zu finden, ist eine ausreichend hohe Anzahl von Trainingsmustern erforderlich. Zusätzlich ist es notwendig, dass die Muster möglichst gleichmäßig im Raum verteilt sind, um dünn besetzte Regionen zu vermeiden. Daher ist eine zufällige Generierung der Trainingsmuster ein geeigneter Ansatz. Der Prozess, um diese Trainingsmuster zu generieren, besteht im Wesentlichen aus 4 Schritten:

1. Zufällige Generierung der Strömungs- und Geometrieparameter
2. Erzeugung des Profils anhand der Geometrieparameter.
3. Berechnung der Strömungslösung mit dem Strömungslöser MISES [16].
4. Die Geometrie-Parameter, die Strömungsparameter und die Strömungslösung werden in der Datenbank gespeichert.

Die zufällige Variation der Profilgeometrie und der Strömungsparameter können ungewöhnliche Profilformen und Strömungsbedingungen zum Ergebnis haben. Viele dieser Variationen führen zu keiner konvergenten Lösung und werden für das Training nicht verwendet. Ansonsten werden alle konvergenten Lösungen zum Training eingesetzt. Dies hat den Vorteil, dass die Ersatzmodelle auch die Performance schlechter Profilgeometrien / Strömungsparameter vorhersagen können und ermöglichen so eine Optimierung auf den Ersatzmodellen.

Zusammengefasst sind sie Anforderungen an die Datenbank:

1. Eine hohe Anzahl von zufällig generierten Trainingsmustern (in dieser Arbeit ca. 10^6)
2. Im Raum gleichmäßig verteilte Trainingsmuster
3. Profilgeometrien/Strömungszustände mit schlechter Performance als Ergebnis werden mit in die Datenbank für das Training aufgenommen.
4. Eine große Variation der Geometrie- und Strömungsparameter

BILD 4 zeigt die Verteilung der Totaldruckverluste über der Machzahl und dem Anströmwinkel für 50.000 zufällig ausgewählte Trainingsmuster.

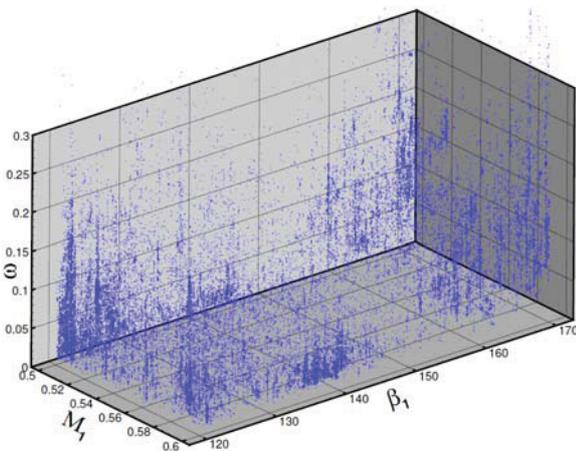


BILD 4. Ausschnitt einer Trainingsmustersverteilung im 3D-Raum

Es ist erkennbar, dass die Verteilung der Trainingsmuster nicht ganz gleichmäßig ist. Der Hauptgrund dafür ist der Algorithmus zur Erstellung der Trainingsmuster. Um den Prozess zu beschleunigen, werden bereits konvergierte Trainingsmuster mutiert und so neue Muster generiert. Dieser Algorithmus hat den Vorteil, mehr konvergente Trainingsmuster zu generieren, ist allerdings nicht vollständig zufällig.

6. DIE VERWENDETEN ERSATZMODELLE

Am DLR-Institut für Antriebstechnik werden Kriging und Neuronale Netze als Ersatzmodelle [2] verwendet. In

dieser Arbeit ist ein Ersatzmodell vonnöten, welches in der Lage ist große Datenmengen zu verarbeiten. Die Trainingszeit von Neuronalen Netzwerken ist linear abhängig von der Anzahl der Trainingsmuster $O(n)$. Kriging Modelle sind hingegen kubisch abhängig von der Anzahl der Trainingsmuster $O(n^3)$. Daher ist die Verwendung von Neuronalen Netzwerken in diesem Fall günstiger. Die hier implementierten Neuronalen Netzwerke sind Bayesisch trainierte Feed Forward Netzwerke [2] und haben einen Ausgangsknoten.

6.1. Aufteilen der Neuronalen Netzwerke

Der einfachste Weg ein Neuronales Netzwerk zur Vorhersage der Profilperformance zu trainieren, wäre das Training eines globalen Neuronalen Netzwerks mit dem gesamten Datenbankinhalt. Allerdings wäre die Rechenzeit für das Training mit 10^6 Trainingsmustern selbst bei Neuronalen Netzwerken unrealistisch hoch. Aus diesem Grund wurden die Neuronalen Netzwerke in dieser Arbeit in Machzahlbereiche aufgeteilt.

| Machzahl | Neuronale Netzwerke | Neuronale Netzwerke für Sperrern |
|-----------|---------------------|----------------------------------|
| 0,4 - 0,5 | ω, β_2 | |
| 0,5 - 0,6 | ω, β_2 | |
| 0,6 - 0,7 | ω, β_2 | |
| 0,7 - 0,8 | ω, β_2 | |
| 0,8 - 0,9 | ω, β_2 | ω, β_2 |
| 0,9 - 1,0 | ω, β_2 | ω, β_2 |
| 1,0 - 1,1 | ω, β_2 | ω, β_2 |

TAB 2. Aufteilung der Neuronalen Netzwerke in Machzahlen für beide Profilperformance Parameter

TAB 2 zeigt die in dieser Arbeit verwendete Aufteilung. Für jeden Machzahlbereich müssen jeweils ein Neuronales Netzwerk für die Vorhersage der Totaldruckverluste ω und eines für die Vorhersage des Abströmwinkels β_2 trainiert werden. Zudem ist es notwendig, für das Sperrern des Profilhitters eigene Neuronale Netzwerke zu trainieren. BILD 5 zeigt den Totaldruckverlust und Abströmwinkel über dem Anströmwinkel β_1 bei zwei verschiedenen Machzahlen. Beim Sperrern des Profilhitters ist erkennbar, dass der Totaldruckverlust und der Abströmwinkel keine eindeutige Funktion mehr vom Anströmwinkel ist

$$(3) \omega, \beta_2 \neq f(\beta_1, \dots)$$

Aus diesem Grund muss statt des Inputparameters β_1 ein Gegendruck als Inputparameter für den gesperrten Zustand des Gitters verwendet werden.

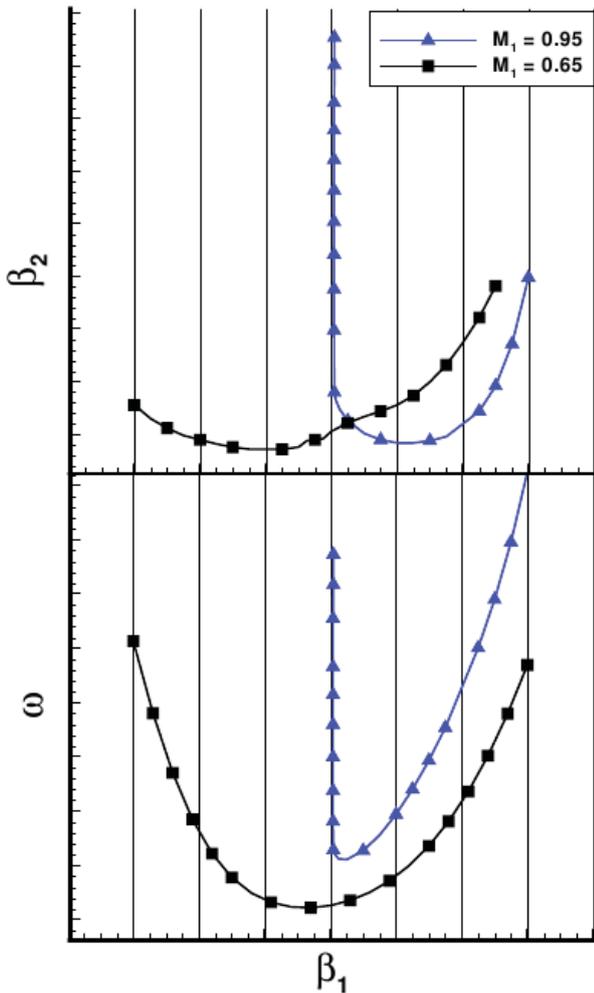


BILD 5. Typische Verlust- und Abströmwinkelkurven

In TAB 2 ist ersichtlich, dass aus diesem Grund zusätzliche Neuronale Netzwerke für den gesperrten Zustand trainiert werden müssen, sowie für die Detektion des Sperrwinkels selbst. In dieser Arbeit sind diese Neuronale Netzwerke für den gesperrten Zustand allerdings noch nicht trainiert worden, deswegen werden sich die Ergebnisse der Testfälle auf den nicht gesperrten Zustand beschränken.

6.2. Optimierung der Neuronalen Netzwerke

Die Güte der Vorhersage eines Neuronales Netzes ist stark an dessen Struktur gekoppelt (Anzahl der Knoten, Schichten, Gewichte etc.). Um das bestmögliche Ergebnis zu erzielen, wurde das Optimierungstool AutoOpti [14] verwendet, um den Vorhersagefehler der Neuronales Netzwerke zu minimieren. Die freien Variablen für das Neuronales Netzwerk waren die Anzahl der Knoten in den verborgenen Schichten, die Startwerte der Hyperparameter und die Konnektivität zwischen der Eingangs- und der ersten verborgenen Schicht. Um die Zeit für das Training in Grenzen zu halten, wurde die

Anzahl der Gewichte für ein Neuronales Netzwerk auf 3000 begrenzt. Die Optimierung wurde auf einem Supercomputer durchgeführt und dauerte für alle Machzahlbereiche auf ca. 80 Intel Xeon Kernen ca. 2 Wochen. Zielfunktion der Optimierung war die Minimierung des Mittleren Fehlers zwischen der Vorhersage der Neuronales Netzwerke und 1000 zufällig erstellten Testmustern.

$$(4) \text{ Mittlerer Fehler} = \sqrt{\frac{1}{N} \sum_{i=1}^N (f(x_i) - y(x_i, w))^2}$$

$(f(x_i) - y(x_i, w))^2$ ist der quadrierte Fehler zwischen der Profilperformance eines Testmusters $f(x_i)$ und der Vorhersage eines Neuronales Netzwerks $y(x_i, w)$ mit dem Parametervektor x_i und dem Gewichtsvektor des Neuronales Netzwerks w . N ist die Anzahl der verwendeten Testmuster, in diesem Fall 1000. Die Testmuster sind vollkommen unabhängig von der Datenbank, die für das Training der Neuronales Netzwerke verwendet worden ist.

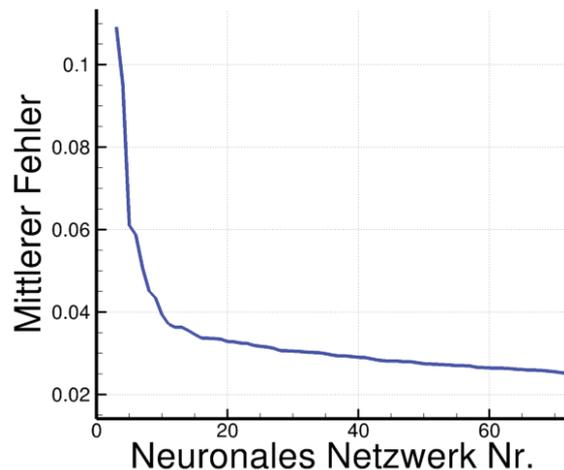


BILD 6. Mittlerer Fehler der Totaldruckverlustvorhersage während des Optimierungsverlaufs

In BILD 6 ist der Optimierungsverlauf einer Topologieoptimierung von Neuronales Netzwerken zu erkennen. Auf der X-Achse ist die Nr. eines während der Optimierung erzeugten Neuronales Netzwerks zu erkennen. Diese Achse entspricht also in etwa dem zeitlichen Optimierungsverlauf. Die Y-Achse zeigt den in Gleichung (4) beschriebenen Mittleren Fehler. Es ist ersichtlich, dass der Mittlere Fehler während des Optimierungsverlaufs drastisch abnimmt.

7. TESTFALL – 4,5 STUFIGER AXIALVERDICHTER RIG250

Der neue Ansatz wird an Rotor 1 des 4,5 stufigen transsonischen Verdichters RIG250 mit einem Druckverhältnis von 4,83 bei 46,3 kg/s reduziertem Massenstrom und einer Drehzahl von 12960 min^{-1}

getestet.

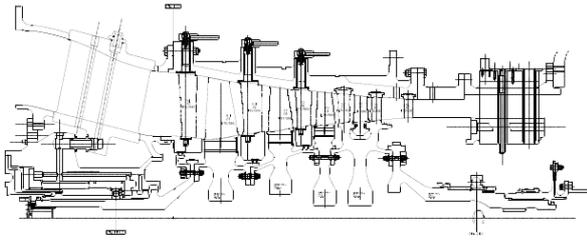


BILD 7. Querschnitt des DLR Test Rig „RIG250“

Es wurden insgesamt 3 verschiedene Tests durchgeführt, um die Eignung der Ersatzmodelle im Vorauslegungsprozess zu validieren.

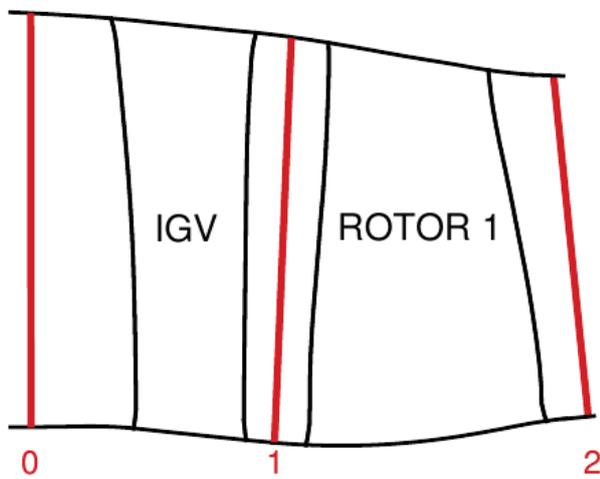


BILD 8. Auswerteebenen der Rechnung

7.1. Vergleich Rotor 1: 2D-Throughflow

Als erstes wurden zwei Drehzahllinien bei 80% und 70% der Nenn Drehzahl berechnet. Einmal wurde die Rechnung mit dem 2D-Throughflow-Solver ACDC gekoppelt mit den Neuronalen Netzwerken durchgeführt und einmal mit dem 3D-CFD-Solver TRACE als Referenz. TRACE [3, 1] ist ein DLR interner 3D-CFD-Solver, welcher seit über 20 Jahren entwickelt wird und von MTU Aeroengines validiert und verwendet wird.

BILD 8 zeigt die Auswerteebenen der 3D CFD und der 2D Throughflow Rechnung. Die 2D Rechnung wurde nur für Rotor 1 durchgeführt (zwischen Auswerteebene 1 und 2). Die 3D-CFD Rechnung wurde mit IGV durchgeführt und die Eintrittsrandbedingungen von Rotor 1 für die 2D Rechnung aus der 3D-CFD Rechnung übernommen. Da sich die Sperrgrenzvorschau noch in der Entwicklung befindet, wurde die 100% Drehzahllinie nur mit 3D-CFD berechnet.

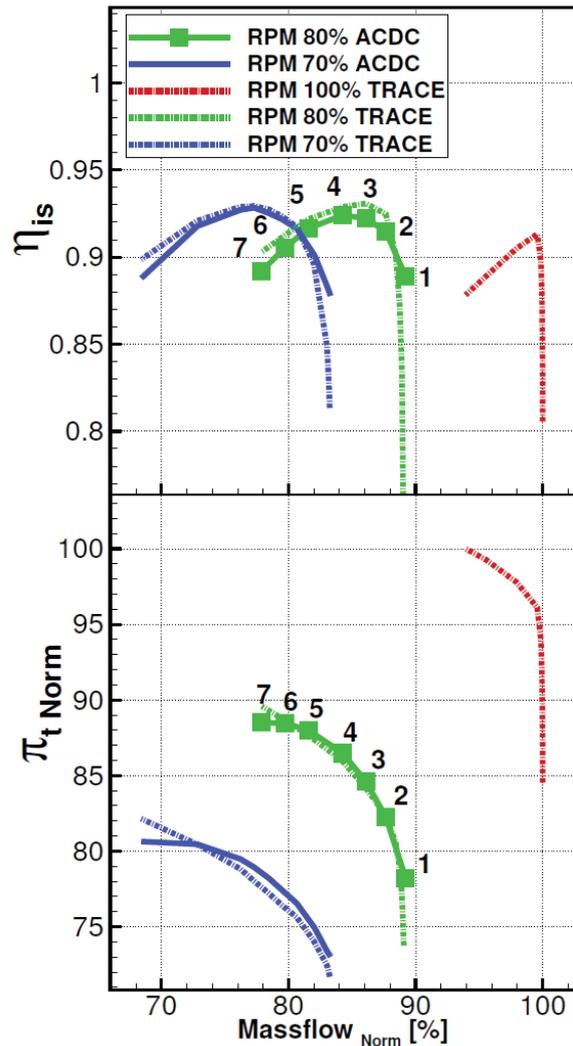


BILD 9. Das mit dem 2D-Solver ACDC und dem 3D-CFD Verfahren TRACE berechnete Kennfeld von Rotor 1

In BILD 9 kann man das Kennfeld von Rotor 1 des Verdichters RIG250 sehen. Die Übereinstimmung zwischen der 3D-CFD und 2D-Throughflow Rechnung ist für beide Drehzahllinien sehr gut. Das 2D-Throughflow-Verfahren gekoppelt mit den Neuronalen Netzwerken gibt das Off-Design-Verhalten des Rotors korrekt wieder. Die 3D-CFD Rechnung der 100% Drehzahllinie wird hier nur der Vollständigkeit halber dargestellt.

In BILD 10 sind die radialen Verteilungen verschiedener Kennwerte von Betriebspunkt 3 und 6 (beide 80% Drehzahl) zu sehen. Die Betriebspunkte 3 und 6 sind im BILD 9 markiert; die Kennzahlen wurden zwischen den Auswerteebenen aus BILD 8 ermittelt.

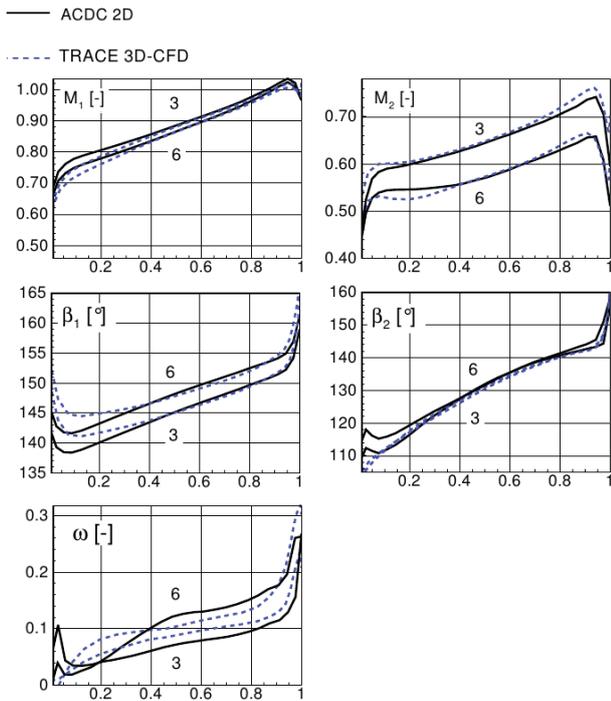


BILD 10. Radiale Verteilung einiger Kennwerte von Betriebspunkt 6 und 3

Die Eintrittsmachzahl variiert zwischen 0,65 an der Nabe und 1,03 am Gehäuse. In den oberen 40% relativer Höhe der gezeigten Betriebspunkte 3 und 6 herrscht eine transsonische Strömung.

In den unteren 30% kann man eine Diskrepanz der Zuströmbedingungen zwischen dem 3D-CFD Solver und der 2D-Throughflow Rechnung erkennen. Da die Zuströmbedingungen für den 2D-Solver aus 3D-Rechnung kommen, ist dies auf den ersten Blick verwunderlich. Es lässt sich allerdings auf das Turbulenzmodell und das Grenzschichtmodell zurückführen. Die Turbulenz- und Grenzschichtgrößen hinter dem IGV lassen sich nur äußerst schwer von der 3D-Rechnung in die Eintrittsrandbedingungen der 2D-Rechnung übertragen. Zukünftig sollte daher das IGV mit in die 2D-Rechnung übernommen werden, sodass das Turbulenzmodell des 2D-Solvers dort bessere Ergebnisse liefern sollte.

Die Austrittswinkel- und Verlustverteilung ist insgesamt in sehr guter Übereinstimmung und gibt insbesondere das Off-Design Verhalten des Verdichters in korrekter Weise wieder. Die Anströmung sowie die Profیلgeometrien variieren (von subsonischer bis transsonischer Zuströmung) über der relativen Höhe des Rotors. Diese Änderungen werden von den Neuronalen Netzwerken sehr gut wiedergegeben. Dies spricht sehr für die Eignung von den hier vorgeschlagenen Ersatzmodellen für die Vorhersage der Profیلperformance. Zusätzlich sollte noch erwähnt werden, dass die Profile von Rotor 1 nicht in der Trainings- und Testdatenbank der Neuronalen Netzwerke enthalten waren.

7.2. Vergleich Rotor 1: Mittelschnitt

Im Folgenden soll eine Verlust- und Austrittswinkelkurve des Mittelschnitts von Rotor 1 mit dem 2D Blade to Blade Solver MISES, den Neuronalen Netzwerken und dem 3D CFD Verfahren TRACE verglichen werden. Die notwendigen Anströmbedingungen und Betriebspunkte für das Mittelschnittsprofil entsprechen denen aus der 3D-CFD Rechnung (BILD 9).

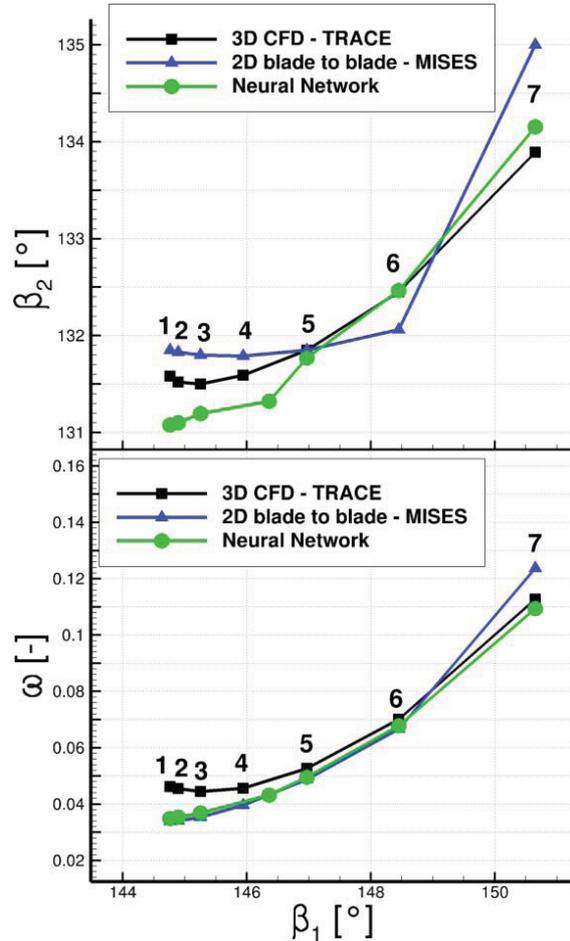


BILD 11. Vergleich der Verlust- und Abströmwinkelkurve mit verschiedenen Verfahren

BILD 11 zeigt den Vergleich zwischen dem 3D-CFD-Solver TRACE, dem 2D-Blade to Blade Solver MISES und den Vorhersagen der Neuronalen Netzwerke. Auf der X-Achse ist der Anströmwinkel β_1 aufgetragen, auf der Y-Achse des oberen Diagramms ist der Abströmwinkel β_2 aufgetragen und im unteren Diagramm der Totaldruckverlust ω . Die Vorhersage der Totaldruckverluste durch die Neuronalen Netzwerke ist in sehr guter Übereinstimmung mit den Ergebnissen aus MISES. Auch zu den 3D-CFD Ergebnissen zeichnen sich nur geringe Unterschiede ab.

Der Unterschied zwischen den Neuronalen Netzwerken und MISES liegt in diesem Beispiel in dem Bereich des Unterschieds zwischen dem 3D-CFD Solver und MISES. Insgesamt scheint die Verwendung der Ersatzmodelle in einem Auslegungstool wie ACDC als äußerst sinnvoll.

7.3. Optimierung auf den Ersatzmodellen des Mittelschnittprofils von Rotor 1

Um die Eignung der Ersatzmodelle für eine Optimierung zu testen und ihre globale Gültigkeit festzustellen, wurde eine Optimierung des Mittelschnittprofils von Rotor 1 durchgeführt. Die Optimierung hat nur auf den trainierten Ersatzmodellen stattgefunden. Es wurden dieselben Randbedingungen für den Mittelschnitt angenommen wie sie bei dem originalen Profil auf der 80% Drehzahllinie zu finden waren (Kapitel 7.2).

| Randbedingung | Minimale Grenze | Maximale Grenze |
|----------------------|-----------------|-----------------|
| β_{2ADP} | 133,6° | 132,6° |
| $\beta_{2NEARSTALL}$ | 134,5° | 130,5° |

TAB 3. Randbedingungen der Optimierung des Mittelschnittprofils von Rotor 1

In TAB 3 sind die wichtigsten Randbedingungen aufgelistet. Es wurden 2 Betriebspunkte optimiert. Einer der Betriebspunkte sollte möglichst niedrige Verluste aufweisen (ADP) und der andere Betriebspunkt sollte bei möglichst hoher Inzidenz die Pumpgrenze simulieren (NEARSTALL). Einer der Randbedingungen war es, die Umlenkung in beiden Betriebspunkten gleich zu halten oder im besten Fall etwas zu erhöhen. Zudem wurden die Eintrittsrandbedingungen des Originalprofils übernommen.

Zielfunktion der Optimierung war zum einen die Minimierung der Totaldruckverluste im ADP (ω_{ADP}) und zum anderen die Minimierung der Totaldruckverluste nahe der Pumpgrenze ($\omega_{NEARSTALL}$) unter Einhaltung der oben genannten Randbedingungen.

| Parameter Name | Minimale Grenze | Maximale Grenze |
|----------------|-----------------|-----------------|
| β_{ST} | 110° | 150° |
| β_{LE} | 130° | 160° |
| β_{TE} | 100° | 140° |
| x_{DeBoor} | 0,3 | 0,7 |
| y_{DeBoor} | 0,04 | 0,2 |

TAB 4. Parameter Freigaben der Optimierung

In TAB 4 sind die Parameterfreigaben der Optimierung zu erkennen. Es wurden alle Winkel in einem sehr weiten Bereich freigegeben und ein DeBoor Punkt, um die Saugseitenkrümmung zu beeinflussen. Die Grenzen wurden so groß gewählt, um die globale Gültigkeit der Neuronalen Netzwerke testen zu können. Ein Startpunkt für die Optimierung wurde nicht gewählt, um das Ergebnis nicht zu beeinflussen. Die Optimierungsparameter wurden auf eine möglichst globale Suche hin eingestellt und dauerte die Rechenzeit betrug 2h auf 16 Intel Xeon Kernen. Aufgrund der sehr kurzen Laufzeit der Vorhersagen konnten innerhalb der Optimierung ca. 50.000 Member generiert werden.

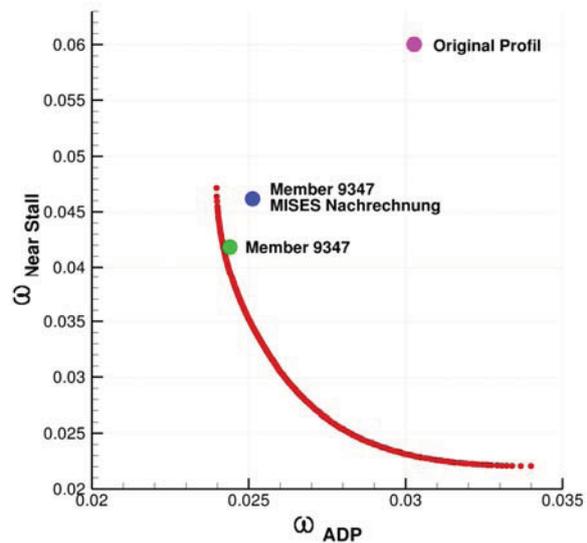


BILD 12. Paretofront der auskonvergierten Optimierung

In BILD 12 ist die Paretofront der auskonvergierten Optimierung zu erkennen. Aufgetragen sind die beiden Zielfunktionen. Zusätzlich aufgetragen sind das Originalprofil und ein Profil (Member 9347), welches im Weiteren genauer untersucht werden soll. In blau ist die MISES Nachrechnung des optimierten Profils 9347 eingetragen. Es ist ersichtlich, dass der Unterschied zwischen der Neuronalen Netzwerk Vorhersage und der MISES Nachrechnung nur sehr klein ausfällt. Die

Verbesserung des Originalprofils ist allerdings äußerst hoch; die Totaldruckverluste konnten im Betriebspunkt nahe der Pumpgrenze von ca. 0,06 auf 0,042 und im ADP Betriebspunkt von 0,031 auf 0,024 reduziert werden.

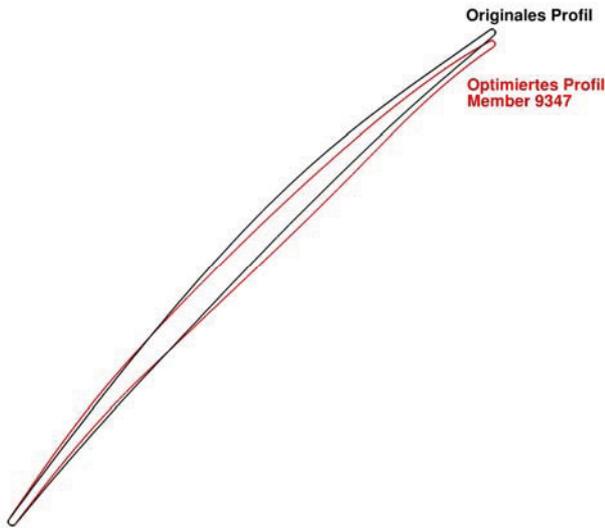


BILD 13. Geometrie des Originalprofils und des optimierten Profils 9347

In BILD 13 werden die Geometrien des Originalprofils und des optimierten Profils 9347 verglichen. Trotz der sehr großen geometrischen Freigaben (TAB 4) ähnelt das aus der Optimierung stammende Profil dem originalen Profil stark. Da das originale Profil aus einer realen Maschine stammt und davon auszugehen ist, dass dieses bereits optimiert ist, ist die Ähnlichkeit der beiden Profile ein Zeichen für die globale Gültigkeit dieses neuartigen Ansatzes.

In BILD 14 ist ein Vergleich der Verlust- und Abströmwinkelkurven zwischen dem optimierten Profil 9347 und dem originalen Profil dargestellt. Die Werte des Originalprofils entsprechen denen aus BILD 11. Zum Vergleich wurden bei dem optimierten Profil einmal die Kurve der Neuronalen Netzwerk Vorhersage und die Nachrechnung mit MISES als Referenz dargestellt. Es ist ersichtlich, dass die Totaldruckverluste in allen Betriebspunkten durch die Optimierung verringert werden konnten. Zudem wurde der Austrittswinkel in allen Punkten gesenkt, was einer höheren Umlenkung entspricht.

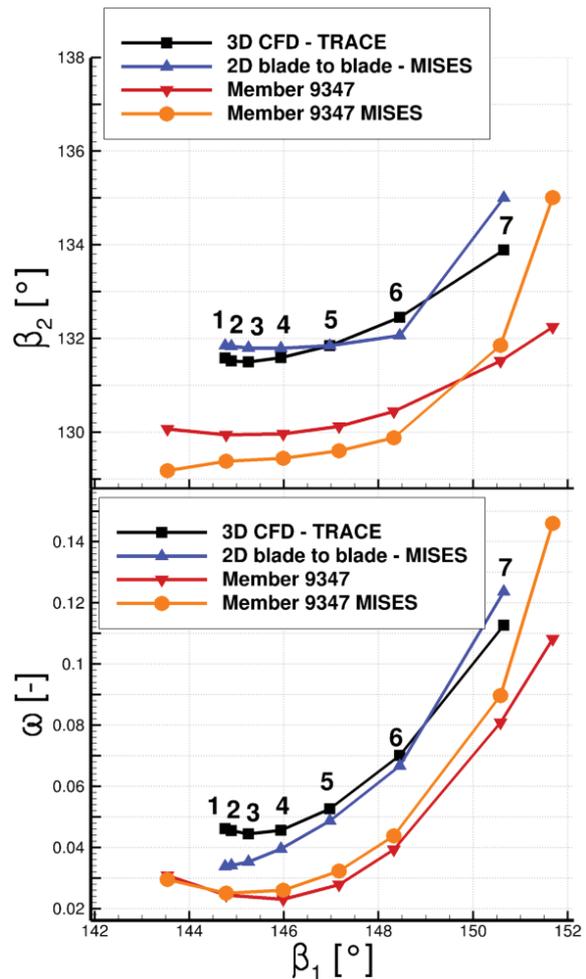


BILD 14. Vergleich der Verlust- und Abströmwinkelkurve des optimierten Profils 9347 und des Originalprofils

In BILD 15 ist die Profilmachzahlverteilung aus der Nachrechnung von MISES für das Originalprofil, sowie für das Optimierungsergebnis mit den Randbedingungen der Betriebspunkte 1 und 6 dargestellt. Bei der Interpretation des Optimierungsergebnisses muss berücksichtigt werden, dass die Randbedingungen der 80% Drehzahllinie - also einer Teildrehzahl des Versuchsverdichters - verwendet worden sind. Daraus erklärt sich die Machzahlverteilung des Originalprofils im oberen Diagramm des BILD 15 mit der hohen Überexpansion um die Vorderkante und dem starken Stoß bei etwa 10% Sehnenlänge. Das Auslegungsergebnis zeigt, wie zu erwarten war, dass diese hohe Inzidenz durch Umstaffelung reduziert wurde. Die Stoßstärke und die daraus resultierende Stoß-Grenzschichtwechselwirkung wurden gemildert und die Verluste konnten entsprechend reduziert werden.

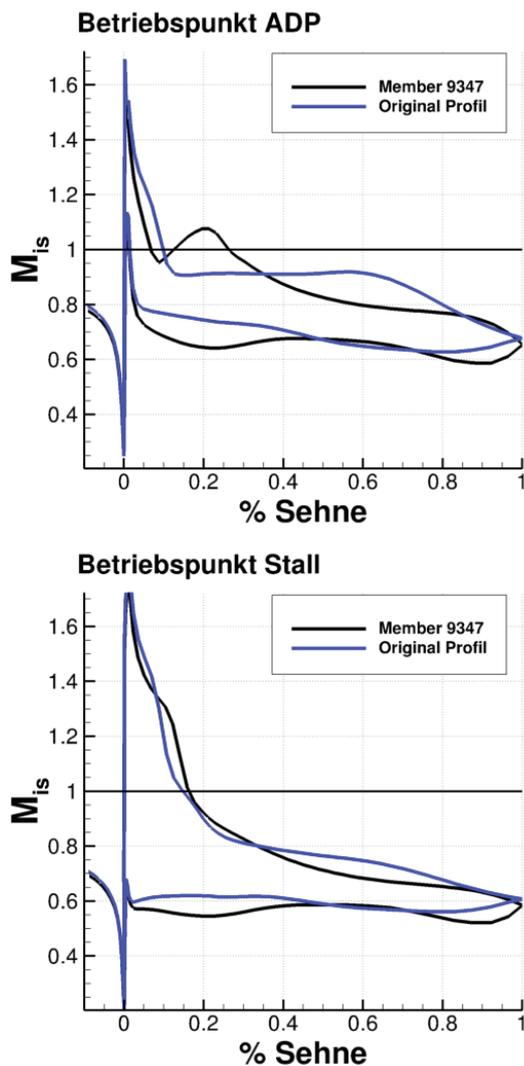


BILD 15. Vergleich Profilmachzahlverteilung des Originalprofils mit dem optimierten Profil 9347 bei Betriebspunkt 1 und 6 (siehe BILD 14; Nachrechnung MISES)

Dieses Ergebnis zeigt, dass die trainierten Ersatzmodelle in einer Optimierung verwendet werden können und eine sehr weite Gültigkeit und hohe Genauigkeit aufweisen. Zukünftig sollen diese Modelle zur 2D-Optimierung eines Mehrstufigen Verdichters verwendet werden.

8. ZUSAMMENFASSUNG UND AUSBLICK

Eine neuartige Methodik zur Vorhersage der Profildatenbank basierend auf einer Profildatenbank in Verbindung mit Ersatzmodellen wurde vorgestellt. Zum Erstellen der Profildatenbank ist eine Parametrisierung gewählt worden, die bereits ein breites Spektrum an Profildatenbanken und Strömungszuständen abdeckt. Momentan wird auch eine verbesserte Parametrisierung getestet, welche sich besser für die Ersatzmodelle eignet und ein noch breiteres Spektrum an Profildatenbanken zulässt. Ein automatischer Prozess zum Generieren einer Profildatenbank wurde entwickelt und verwendet, um eine Datenbank mit ca. 10^6 Profilen zu erstellen. Dieser

Prozess basiert auf AutoOpti, ein automatischer Optimierer, welcher am DLR-Institut für Antriebstechnik [2, 14] entwickelt worden ist. In dieser Arbeit wurden Bayesisch trainierte Neuronale Netzwerke als Ersatzmodell verwendet, da dieser Ansatz in der Lage ist, eine große Anzahl von Trainingsmustern zu verarbeiten. Die Topologie der Neuronalen Netzwerke wurde erfolgreich optimiert, um die Vorhersagegenauigkeit zu erhöhen.

Ein transsonischer Rotor des Verdichters RIG250 wurde zur Validierung verwendet.

Es wurde eine Rechnung mit dem 2D-Throughflow Solver ACDC in Verbindung mit den Neuronalen Netzwerken bei verschiedenen Drehzahlen durchgeführt und ein Vergleich mit einer 3D-CFD Rechnung des Rotors angestellt. Die Drehzahlkurven zeigten eine sehr gute Übereinstimmung mit der 3D-Rechnung. Einige Betriebspunkte konnten bei diesem Test nicht berechnet werden, da sich die Ersatzmodelle für Profildatenbanken im gesperrten Zustand noch in der Entwicklung befinden.

Zudem wurde eine Berechnung des Mittelschnitts von Rotor 1 durchgeführt und mit dem 2D-Blade to Blade Verfahren MISES und dem 3D-CFD Ergebnissen verglichen. Der Unterschied zwischen den Vorhersagen der Neuronalen Netzwerke und MISES lag in derselben Größenordnung wie der Unterschied zwischen dem 3D-CFD Verfahren TRACE und MISES.

Um die globale Gültigkeit und die Eignung der Methodik im Hinblick auf eine Optimierung zu testen, wurde eine Optimierung des Mittelschnitts von Rotor 1 des RIG250 durchgeführt. Hierbei wurden die Randbedingungen des Originalprofils beibehalten und versucht, die Verluste in 2 verschiedenen Betriebspunkten zu senken. Die Optimierung wurde gänzlich auf den Ersatzmodellen durchgeführt. Der Bereich der freigegebenen Parameter wurde sehr groß gewählt, um die globale Gültigkeit der Neuronalen Netzwerke testen zu können. Ein Startpunkt für die Optimierung wurde ebenfalls nicht gewählt, um das Ergebnis nicht zu beeinflussen. Es konnte in allen Betriebspunkten eine Verbesserung erzielt werden. Die Ergebnisse wurden mit MISES nachgerechnet und zeigten nur geringe Unterschiede. Dieses Ergebnis zeigt, dass die trainierten Ersatzmodelle in einer Optimierung verwendet werden können und eine weite Gültigkeit und hohe Genauigkeit aufweisen. Zukünftig sollen diese Modelle zur 2D-Optimierung eines Mehrstufigen Verdichters verwendet werden.

In Bezug auf Genauigkeit und die Anzahl oder Wahl der Geometrie-/ Strömungsparameter ist diese neue Methodik beliebig erweiterbar. Die Genauigkeit kann global oder nur lokal erhöht werden, indem mehr Muster in den gewünschten Bereichen dem Training hinzugefügt werden. Es ist möglich über die Genauigkeitsaussage der Ersatzmodelle festzustellen, ob die Datenbank in dem Bereich ausreichend Trainingsmuster enthält. So kann die Datenbank und die entsprechenden Ersatzmodelle zielgenau für die Anwendung auf neue Schaufeltypen bzw. Verdichterarten erweitert werden. Zusammenfassend kann festgestellt werden, dass der Design-Prozess in Bezug auf Geschwindigkeit und Genauigkeit mit dieser neuen Methodik deutlich verbessert werden kann.

9. LITERATURVERZEICHNIS

- [1] G. ASHCROFT, K. HEITKAMP, and E. KÜGELER.
High-order accurate implicit runge-kutta schemes for the simulation of unsteady flow phenomena in turbomachinery
V European Conference on Computational Fluid Dynamics
ECCOMAS CFD, Lisbon, Portugal, 2010.
- [2] M. AULICH and U. SILLER.
High-dimensional constrained multiobjective optimization of a fan stage.
ASME GT2011-45618, 2011
- [3] K. BECKER, K. HEITKAMP, and E. KÜGELER.
Recent progress in a hybrid-grid cfd solver for turbomachinery flows.
V European Conference on Computational Fluid Dynamics
ECCOMAS CFD, Lisbon, Portugal, 2010.
- [4] M. ÇETIN, AS UÇER, CH HIRSCH, and GK SEROVY.
Application of Modified Loss Correlations to Transonic Axial Compressors.
AGARD Report, 745, 1987.
- [5] HF CREVELING and RH. CARMODY.
Axial-flow compressor computer program for calculating off-design performance.
NASA CR, 72472, 1968.
- [6] JD DENTON.
Throughflow calculations for transonic axial flow turbines. In Turbomachinery developments in steam and gas turbines: Presented at the winter annual meeting of the American Society of Mechanical Engineers, Atlanta, Georgia, November 27-December 2, 1977, page 11. ASME, 1977.
- [7] JD DENTON.
Loss mechanisms in turbomachines.
Journal of Turbomachinery, 115(4):621–656, 1993.
- [8] SJ GALLIMORE.
Spanwise Mixing in Multistage Axial Flow Compressors: Part II—Throughflow Calculations Including Mixing.
Journal of Turbomachinery, 108:10, 1986.
- [9] G. KRÖGER, C. CORNELIUS, and E. NICKE.
Beeinflussung der Spaltströmung durch Optimierung der Geometrie im Schaufelspitzenbereich.
AG-Turbo Abschlussbericht, COORETEC-TURBO Teilvorhaben 1.2.1 des Verbundprojektes CO2-Reduktions-Technologien, 2009., 0327715 A.
- [10] S. LIEBLEIN and NACA. GLENN RESEARCH CENTER.
Analysis of Experimental Low-Speed Loss and Stall Characteristics of Two-Dimensional Compressor Blade Cascades.
National Advisory Committee for Aeronautics, 1957.
- [11] D.J.C. MACKKAY.
Bayesian methods for adaptive models.
PhD thesis, Citeseer, 1991.
- [12] R. MÖNIG, F. MILDNER, and R. RÖPER.
Viscous-Flow Two-Dimensional Analysis Including Secondary Flow Effects.
Journal of Turbomachinery, 123:558, 2001.
- [13] A. SCHMITZ, M. AULICH and E. NICKE
Novel Approach For Loss And Flow-Turning Prediction Using Optimized Surrogate Models In Two-Dimensional Compressor Design
ASME GT2011-45086, 2011