

Suche nach alternativen Gesamtfahrzeugkonzepten mit OptiSLang

Dr.-Ing. Johannes Will¹, Dipl.-Ing. Jörg Riedel¹
Prof. Dr.-techn. Christian Bucher²
Dipl.-Ing. Ingo Raasch³

¹DYNARDO GmbH, Germany, Weimar

²Bauhaus Universität/DYNARDO GmbH, Germany, Weimar

³BMW AG, Germany, München

Zusammenfassung

In der Phase der Fahrzeugkonzeptentwicklung soll der Karosserieentwurf optimiert werden. Die Anforderungen an die Karosserie werden dabei über zahlreiche Performancenebenbedingungen, die aus Crash, Steifigkeits- oder Fahrkomfortanforderungen abgeleitet sind, formuliert. Auf Grund von sehr restriktiven Performanceanforderungen und zahlreicher Konstruktionsrandbedingungen existieren dabei nur extrem kleine Bereiche zulässiger und gewichtsmäßig interessanter Fahrzeugauslegungen. Eine spannende Frage ist, ob im durch die Parametrisierung beschriebenen Designraum konkurrenzfähige Gesamtfahrzeugkonzepte außerhalb bekannter Designs bzw. bekannter Lastpfade existieren. Dann beinhaltet die Optimierungsaufgabenstellung neben einer Optimierung bekannter Fahrzeugkonzepte auch die Suche nach alternativen Gesamtfahrzeugkonzepten. Durch die Kombination von genetischen Strategien für die Suche zulässiger Fahrzeugauslegungen und mathematischer Optimierung zur Gewichtsreduktion auf den Inseln zulässiger Fahrzeugauslegungen konnten unterschiedliche Fahrzeugkonzepte identifiziert werden, die neben der Erfüllung der Anforderungen aus Crash, Steifigkeit und Fahrkomfort auch ein deutlich niedrigeres Gewicht aufweisen, als die mit bisher verwendeten Optimierungsstrategien weiterentwickelten Konzepte.

Keywords: multidisziplinäre Optimierung, genetische Algorithmen, mathematische Optimierung, Clusteranalyse

1 Einleitung und Zusammenfassung

In der Phase des Vorentwurfes soll der Karosserieentwurf optimiert werden. Die Anforderungen an die Karosserie werden dabei über zahlreiche Performancenebenbedingungen, die aus Crash, Festigkeits- oder Fahrkomfortanforderungen abgeleitet sind, formuliert. Am Beginn einer Optimierung stehen oft ein Entwurf oder mehrere Entwürfe zur Verfügung, in denen das Vorwissen bekannter funktionsfähiger Designs repräsentiert ist. Diese Entwürfe werden parametrisiert und so einer parametrischen Optimierung zugänglich. Der Designraum wird in diesem Beispiel mit ca. 1500 Designvariablen beschrieben. Auf Grund von sehr restriktiven Performanceanforderungen und zahlreicher Konstruktionsrandbedingungen existieren im 1500-dimensionalen Designraum dabei nur extrem kleine Bereiche zulässiger und gewichtsmäßig interessanter Fahrzeugauslegungen.

Eine spannende Frage ist, ob im durch die Parametrisierung beschriebenen Designraum konkurrenzfähige Fahrzeugkonzepte außerhalb bekannter Designs bzw. bekannter Lastpfade existieren. Dann beinhaltet die Optimierungsaufgabenstellung neben einer Optimierung bekannter Fahrzeugkonzepte auch die Suche nach alternativen Gesamtfahrzeugkonzepten.

Eine derart formulierte Aufgabenstellung für die Optimierung führt häufig zu mathematisch schlecht konditionierten Problemen. Weil Gewichtsoptimierung und Einhaltung vieler Nebenbedingungen häufig stark gegenläufig sind, zerfällt die Optimierungsaufgabe dann in die Suche und Identifikation von Inseln zulässiger Bereiche (gegebenenfalls alternative Fahrzeugkonzepte) sowie die Gewichtsoptimierung auf den Inseln. Für die Aufgabenstellung der Inselfsuche bieten sich genetische Suchstrategien an. Genetische Strategien zeichnen sich dadurch aus, dass Sie gegenüber mathematisch schlecht konditionierten Optimierungsaufgabenstellungen sehr robust sind und das Vorwissen über die Konstruktion auf verschiedenen Ebenen integriert werden kann. Neben der zur Lösung derartiger Aufgabenstellungen notwendiger Integration von „Wissen“ besitzen genetische Suchstrategien bei geeigneter Wahl der Selektions-, Mutations- und Reproduktionsmechanismen genug Spielraum, um große Suchräume zu durchforsten und nicht im erstbesten lokalen Optima zu enden. Sind Inseln zulässiger Designs gefunden und geeignete Gradienten bestimmbar, sind mathematische Optimierungsmethoden zur Gewichtsoptimierung auf einer Insel zulässiger Designs hocheffizient.

Bei der vorliegenden Aufgabenstellung konnten mit speziellen Samplingstrategien und genetischen Optimierungsverfahren erfolgreich zulässige Fahrzeugauslegungen gefunden werden. Im Anschluss wird mit Clusteranalyse untersucht, ob verschiedene Fahrzeugkonzepte existieren, die alternative Gesamtfahrzeugkonzepte repräsentieren und es wurden geeignete Startpunkte für eine lokale Optimierung bestimmt. Mittels mathematischer Optimierung wurden für ausgewählte Designs in bis zu 20 Clustern gewichtsoptimale Varianten gesucht.

Durch die Kombination von genetischen Strategien für die Suche zulässiger Fahrzeugauslegungen und mathematischer Optimierung zur Gewichtsreduktion auf den Inseln zulässiger Fahrzeugauslegungen konnte signifikant mehr Gewicht als mit den bisher verwendeten Optimierungsstrategien eingespart werden.

Alle strukturmechanischen Berechnungen werden mit NASTRAN durchgeführt. Die mathematische Optimierung mittels Gradientensolver wird mit NASTRAN SOL200 durchgeführt. Die genetische Optimierung sowie die Clusteranalyse werden mit OptiSLang durchgeführt.

2 Optimierung im Vorentwurf

Im frühen Entwurfsstadium sollen die Designräume nach alternativen Fahrzeugkonzepten untersucht werden und die Gesamtfahrzeugmodelle bezüglich des Gewichtes optimiert werden. Wichtige einzuhaltende Performance-Nebenbedingungen aus NVH-, Steifigkeits- oder Crash-Anforderungen werden in 8 statischen (Steifigkeit und Crashersatzlastfälle) sowie in dynamischen Lastfällen (Modalanalyse/Frequenzganganalyse) überprüft. Zuzüglich der Performance-Nebenbedingungen sind zahlreiche Konstruktionsrandbedingungen (> 3000) wie Wandstärkensprünge, Höhen/Seitenverhältnisse, oder Bauraum Anforderungen einzuhalten.

Im Gesamtfahrzeug können dabei 1544 Designvariablen (Profilwerte Höhe/Breite, Blechstärken) modifiziert werden. Alle Variablen werden dabei als kontinuierliche Variablen behandelt.




Abbildung 1: Fahrzeugmodell

Es existiert der klassische Zielkonflikt bei derartigen Optimierungen, dass die Erfüllung der Nebenbedingungen und die Gewichtsminimierung stark gegenläufig sind. Zusätzlich muss davon ausgegangen werden, dass alle Ausgangsdesigns (Startwerte der Optimierung) im unzulässigen Bereich liegen und im hochdimensionalen Designraum nur extrem kleine zulässige Bereiche existieren, die gewichtsmäßig interessant sind und in denen die Performance-Nebenbedingungen erfüllt sind. Es wird davon ausgegangen, dass mehrere „Inseln“ zulässiger Designs existieren, die sozusagen mehrere Basisvarianten zulässiger Gesamtfahrzeugentwürfe repräsentieren. Deshalb ist die Suche nach diesen Inseln ein wichtiger Teil der Optimierungsaufgabenstellung. Der zweite Teil der Aufga-

benstellung besteht dann in der Gewichtsoptimierung auf einer Insel. Deshalb werden in der Folge Algorithmen zur globalen (Inseluche) und zur lokalen (Gewichtsoptimierung auf einer Insel) Optimierung verwendet. Für die Lösung der gesamten Optimierungsaufgabe ist im Entwicklungsprozess ein Zeitfenster von ca. 2 Wochen vorgesehen.

2.1 Bisherige Vorgehensweise

Ausgehend von Best Practise Entwürfen wurden mittels mathematischer Optimierung zahlreiche Optimierungsläufe von verschiedenen Startwerten gestartet. Für eine systematische Suche im Designraum wurden DOE-Verfahren zur Definition von Startwerten getestet. Aus der Vielzahl möglicher Stützstellen im sehr hochdimensionalen Raum wurden daraus ca. 100 Startwerte selektiert. Von diesen Startwerten wurde versucht, mit dem Gradientenoptimierer zulässige gewichtsoptimale Designs zu finden. Das mit dieser Suchstrategie gefundene gewichtsoptimale zulässige Design wiegt 1096 kg und dient in den Abbildungen 9 bis 14 als Vergleichsbasis.

Für die Anwendung der Gradientenoptimierung gibt es bei BMW für die Einstellung geeigneter Steuerparameter sowie zum Starten der Optimierung in zulässigen bzw. unzulässigen Bereich langjährige Erfahrung. Die Formulierung der Zielfunktion hängt davon ab, ob im unzulässigen oder im zulässigen Bereich gestartet wird sowie ob zulässige Designs gesucht werden oder das Gewicht reduzieren will. Darüber hinaus ist es vorteilhaft, die Nebenbedingungen zu Kategorien zusammenzufassen und mit deren Maximalwert sowie Straftermen die Zielfunktion zu erweitern. All diese Erfahrungen wurden bei der obigen bisherigen Lösung der Aufgabenstellung mittels mathematischer Optimierung eingesetzt.

Theoretisch soll das Gradientenverfahren zum nächsten lokalen Minimum führen, deshalb werden Optimierungsverfahren mittels Gradienteninformationen in der Folge als lokale Optimierungsverfahren bezeichnet. Doch auf Grund der Numerik, der Nichtlinearität und der endlichen Schrittweite ist es möglich, im Laufe der Iterationen in ein anderes Minimum-Tal abzudriften. Daher ist es nicht möglich, den zurückgelegten Weg einer Gradientenoptimierung als Vertrauensbereich eines Optimums zu definieren. Damit wird die Gradientenoptimierung zu einem „zufallsbedingten“ Suchverfahren mit hoher Wahrscheinlichkeit, dass der gefundene Zustand auch zulässig ist. Der Aufwand dafür ist nicht ganz unerheblich, wenn eine Funktionsauswertung im hier betrachteten Fall ca. 10 Minuten benötigt, dauert eine Gradientenoptimierung um einen Faktor 60-100 länger. Dies legte es nahe, Verfahren der globalen Optimierung mittels genetischer Suchstrategien mit in Betracht zu ziehen.

2.2 Motivation des hybriden Berechnungskonzepts

Auch wenn für das Problem geeignete Gradienten bestimmbar sind und der Gradientensolver den Weg in zulässige Designbereiche findet, ist zu vermuten, dass Gradientensolver nur auf einer Insel Optima erfolgreich bestimmen kann. Für die globale Suche potentiell verschiedener Inseln schlagen wir deshalb ein genetisches Suchverfahren vor. Weil die Einhaltung von Nebenbedingungen und die Gewichtsoptimierung stark gegenläufig sind, werden die Operatoren der geneti-

schen Optimierung so eingestellt, dass vorrangig Inseln zulässiger Designs gesucht werden. Dabei soll möglichst wenig Gewicht angelagert werden. Es wird erwartet, dass zulässige Designs der genetischen Optimierung dann noch nennenswert Potential zur Gewichtseinsparung besitzen. Zur Gewichtsoptimierung auf den Inseln sollen aus Effizienzgründen in der Folge Gradientenoptimierer verwendet werden. Weil gegebenenfalls viele gültige Design als Startwert der Gradientenoptimierung zur Verfügung stehen, sollen mittels Clusteranalyse die Menge gültiger Designs auf alternative Fahrzeugkonzepte sowie geeignete Startwerte für die Gewichtsoptimierung bestimmt werden.

Extrem wichtig für die Performance der genetischen Suchstrategie ist, dass möglichst viel Know-how aus den bisherigen Best Practise Entwürfen/Konzepten in die Startgeneration einfließt, bzw. Know-how aus Optimierungsschritten weitergegeben werden kann. Dieses Know-how wird in die Startgeneration, in Nebenbedingungen und Zielfunktionsbestandteile sowie in die Operatoren der genetischen Suchstrategie integriert.

Im Lauf der Bearbeitung zeigte sich schnell, dass die Erzeugung einer Startgeneration mittels stochastischer Samplingverfahren im Originalraum (1500 Optimierungsvariablen mit unterer und oberer Grenze) ausschließlich zu gewichtsmäßig uninteressanten Startdesigns führt. Es existiert also nur ein extrem kleiner gewichtsmäßig interessanter Unterraum im durch die Grenzen der Optimierungsvariablen definierten Designraum. Zur Generation einer geeigneten Startgeneration wurde es deshalb notwendig, vom bisherigen Konstruktionsstand ausgehend, eine Startgeneration durch hierarchische Mutation zu erzeugen und in einen gewichtsmäßig interessanten Bereich zu verschieben.

2.3 Globale Optimierung mittels genetischer Suchstrategien

Natürlich spielt bei der Wahl der genetischen Operatoren und der Größe und Anzahl der Generation der CPU Aufwand einer Durchrechnung aller Lastfälle eine entscheidende Rolle. Damit genetische Strategien eine Chance haben (außerhalb zufälliger Designverbesserungen wie mittels Monte Carlo Verfahren) genetische Intelligenz aufzubauen und diese zur Designverbesserung zu nutzen, sind in moderaten Designräumen (10 bis 100 Variablen) nach unseren Erfahrungen mindestens 50 Designauswertungen (5 Generation a 10 Designs) notwendig. In Designräumen von 100 bis 1000 Variablen ist davon auszugehen, dass mehr als 10 Generationen a 10 Designs benötigt werden, um ein ausreichend gutes genetisches Gedächtnis aufzubauen. Weil im vorliegenden Fall eine komplette Durchrechnung aller Lastfälle auf einer CPU weniger als 10 Minuten kostet, und ein Linux-Cluster mit 20 CPU zur Bearbeitung zur Verfügung stand, konnte die genetische Strategie großzügig auf ca. 10.000 Durchrechnungen ausgerichtet werden und es wurde für die erste Stufe der globalen Optimierung eine Generationsgröße von 50 und eine Generationsanzahl von 100 gewählt. Eine relativ große Startgeneration wurde gewählt, um mit hoher Wahrscheinlichkeit mehrere Designinseln zu finden.

Bei einer derart großen Anzahl von Optimierungsvariablen treten erwartungsgemäß nennenswerte Korrelation (Abhängigkeiten) zwischen den Variablen auf. Deshalb wurde die hierarchische Struktur des Variablenbaumes bei Generierung

der Startgeneration berücksichtigt. Dabei wurde eine Hierarchie von 11 Baugruppen, wie z.B. Vorbau, Stirnwand, Boden oder Heck und 44 Bauteilen, wie Stossfänger, Motorträger oder Federbeindom berücksichtigt.

Die Startgeneration von 50 Designs wurde unter Ausnutzung der Hierarchie um ein Referenzdesign mittels Latin Hypercube Sampling erzeugt. Dabei wurden folgende Mutationen verwendet:

- die Baugruppen wurden mit einer Standardabweichung von 0.2 um das Referenzdesign gesampelt (entspricht einer Streuung um das Referenzdesign im 2 Sigma-Wert von $\pm 40\%$)
- zusätzlich wurden in jedem Bauteil mit einer Standardabweichung von 0.05 um das Referenzdesign gesampelt (entspricht einer Streuung um das Referenzdesign im 2 Sigma-Wert von $\pm 10\%$)

Um Inseln mit möglichst wenig Gewicht zu finden wurde danach die Startgeneration und den Gewichtsraum vermuteter gewichtsoptimaler, gültiger Designs von ca. 1100 kg skaliert

2.4 Zielfunktion und Nebenbedingungen für die globale Optimierungen

Die Zielfunktion in der Genetik (sogenannte Fitness) setzt sich aus der Zielfunktion der Optimierungsaufgabenstellung sowie Termen aus den Nebenbedingungen zusammen.

Als Zielfunktionsbestandteile werden Gewicht und Bauraum definiert. Als Nebenbedingungen werden Anforderungen an Steifigkeiten (Deformationen), an Eigenfrequenzen sowie an Abstände zwischen Eigenfrequenzen, an Spannungen sowie an Beschleunigungswerte aus der harmonischen Analyse definiert. Dabei werden alle Nebenbedingungen einer Anforderungsklasse (z.B. Nebenbedingungen an Eigenfrequenzen) zusammengefasst. Sind dabei alle Nebenbedingungen einer Klasse eingehalten ergibt sich ein summarischer Wert von kleiner 1,0. Sind einzelne oder mehrere Nebenbedingungen überschritten, ergibt sich ein summarischer Wert von größer 1,0. Für alle Nebenbedingungen werden skalierte Strafterme für die Fitnessfunktion verwendet. Die Skalierung ist so gewählt, dass eine Einhaltung der Nebenbedingung mit Eins bewertet wird. Bei Überschreitungen wachsen die skalierten Werte bis auf maximal 400. Zusätzlich wird zur sicheren Unterscheidung zulässiger und unzulässiger Design ein konstanter Strafterm auf die Fitnessfunktion addiert, wenn eine oder mehrere Nebenbedingungen verletzt sind.

Die Operatoren der Evolutionsstrategie (Elitismus, Selektion, Reproduktion, Mutation) werden so gewählt, dass in den genetischen Optimierungsstrategien schwerpunktmäßig der Designraum nach zulässigen Designs durchsucht wird.

Die konstruktiven Nebenbedingungen werden nach der Erstellung der Designvarianten geprüft und im Fall von Überschreitungen „repariert“. Damit wird sichergestellt, dass nur Designs bewertet werden, die den Konstruktionsrandbe-

dingungen genügen. Die reparierten Werte der Designvariablen werden dem Optimierer vor der Durchrechnung wieder mitgeteilt.

3 Globale und lokale Optimierung

3.1 Globale Optimierung – Inselsuche mit genetischen Optimierungsstrategien

Folgende Einstellungen der genetischen Optimierungsstrategie wurden gewählt:

- Es werden 50 Individuen pro Generation sowie 100 Generationen berechnet.
- Inselsuche mit Startgeneration, die mit Wissen der Baugruppen/Bauteilhierarchie um das Referenzdesign erzeugt wird und in einen interessanten Gewichtsraum skaliert wird.
- Nach jeder Generationsdurchrechnung werden 2 Elite mit Roulettradlogik und 99-prozentigen Skalierung des Roulettrades ermittelt und unverändert in die nächste Generation übernommen.
- Nach jeder Generationsdurchrechnung werden 10 schlechteste Design mit Roulettradlogik ermittelt und aus der Generation entfernt.
- Aus dem Genpool der aktuellen Generation werden dann wiederum mittels skaliertes Roulettllogik die Elternpaare ausgespielt.
- Der genetische Austausch erfolgt mittels einer Austauschwahrscheinlichkeit (uniform crossover) von 8%.
- Die Mutationsrate beträgt 17 %. Zur Mutation wird eine Standardabweichung von 0.03 im auf 1 normierten Raum der Optimierungsvariablen von unterer zu oberer Grenze verwendet. Diese Mutationsrate wird linear im Lauf der 100 Generationen auf 0.01 gesenkt.

Nach ca. 15 Generationen (750 Durchrechnungen) konnte der genetische Algorithmus ein ausreichend gutes genetisches Gedächtnis aufbauen, um erfolgreiche Gene und Suchrichtungen zu identifizieren, die zu einer kontinuierlichen Verbesserung der Nebenbedingungen führten. Nach 3348 Durchrechnungen (67 Generationen) wurde die Optimierung angehalten. Bis dahin konnte noch kein zulässiges Design gefunden werden, dass alle Nebenbedingungen erfüllt. Die Auswertung der Optimierung zeigte folgende Trends:

- Die Erfüllung der Nebenbedingung Steifigkeit zeigt einen guten Trend und ist ab Generation 60 (3000 Durchrechnungen) sicher erfüllt (Abbildung 2).
- Die Überschreitung der Nebenbedingung Eigenfrequenzen zeigt einen guten Trend in die positive Richtung, ist allerdings immer noch leicht überschritten (Abbildung 3).
- Das Gewicht wird in der Optimierung mit eindeutigem Trend erhöht und stagniert ab Generation 60 auf einem Niveau von ca. 1120 kg (Abbildung 4). Ebenso wird der Bauraum in der Optimierung mit eindeutigem Trend erhöht (Abbildung 5).

- Der erste Biegemode wird mit eindeutigem Trend erhöht (Abbildung 6).
Der erste Torsionsmode (Abbildung 7) wird mit klarem Trend erhöht.




Abbildung 2: Historie Nebenbedingungen Steifigkeit, ab einem Wert von 1.0 (fette horizontale Linie) sind die Nebenbedingungen erfüllt

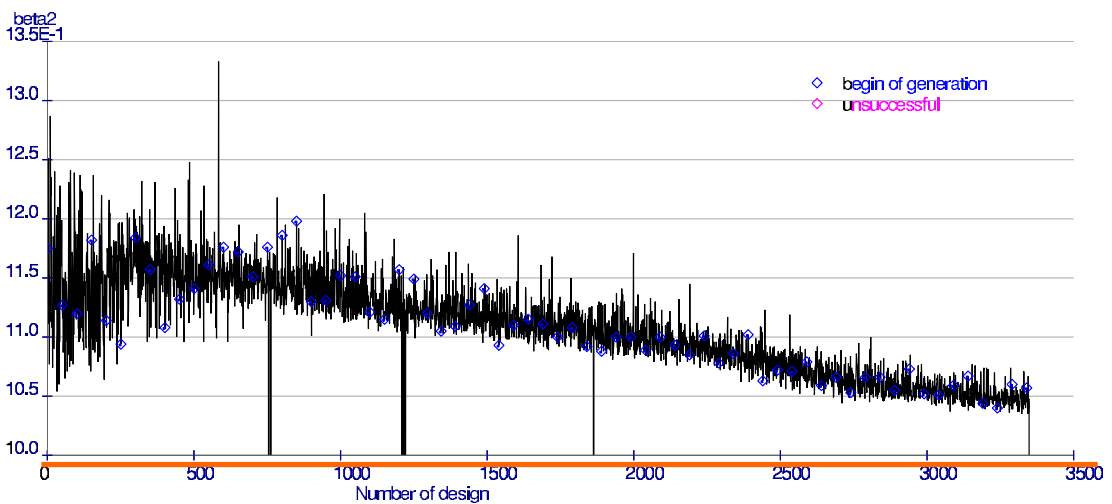


Abbildung 3: Historie Nebenbedingungen Eigenfrequenzen, ab einem Wert von 1.0 (fette horizontale Linie) sind die Nebenbedingungen erfüllt

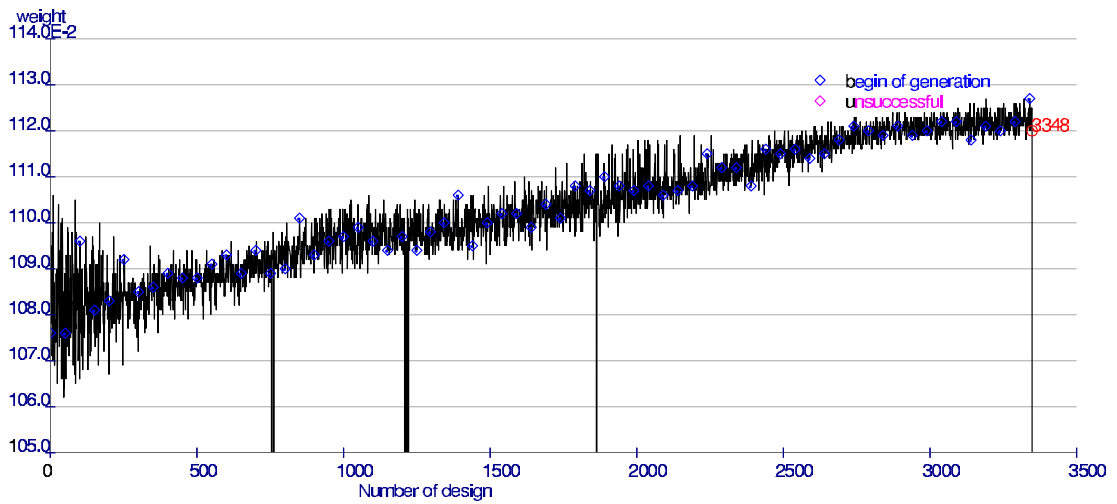


Abbildung 4: Historie Gewicht




Abbildung 5: Historie Bauraum




Abbildung 6: Historie erster Biegemode




Abbildung 7: Historie erster Torsionsmode

3.2 Restart der genetischen Optimierung

Für den Restart der genetischen Optimierung wird das Vorwissen aus der vorangegangenen Optimierung in die Startgeneration integriert und die Einstellungen der Genetik werden angepasst:

- Es werden 100 Individuen pro Generation sowie 100 Generationen berechnet.
- Die Startpopulation von 100 Designs wurde aus den Designs der vorangegangenen Optimierung zusammengestellt, welche die Nebenbedingungen am besten erfüllten.
- Nach jeder Generationsdurchrechnung werden 5 Elite mit Roulettradlogik und 90-prozentigen Skalierung des Roulettrades ermittelt und unverändert in die nächste Generation übernommen.
- Nach jeder Generationsdurchrechnung werden 10 schlechteste Design mit Roulettradlogik ermittelt und aus der Generation entfernt.
- Aus dem Genpool der aktuellen Generation werden dann wiederum mittels skaliertes Roulettlöge die Elternpaare ausgespielt.
- Der genetische Austausch erfolgt mittels einer Austauschwahrscheinlichkeit (uniform crossover) von 10%.
- Die Mutationsrate beträgt 15%. Zur Mutation wird eine Standardabweichung von 0.05 im auf 1 normierten Raum der Optimierungsvariablen von unterer zu oberer Grenze verwendet. Diese Mutationsrate wird linear im Lauf der 100 Generationen auf 0.03 gesenkt.

Mit der angepassten genetischen Optimierungsstrategie wurde versucht, durch größeren genetischen Austausch und größerer Mutation die Konvergenzgeschwindigkeit der Erfüllung der Nebenbedingungen zu erhöhen. Gleichzeitig wurde ein stärkerer Elitismus verwendet, um die genetische Optimierung auf die bisher besten Design zu konzentrieren. Um die Wahrscheinlichkeit einer erwun-

genen Konvergenz zu lokalen Optima zu minimieren wurde die Generationsgröße erhöht. Wie an den folgenden Ergebnissen zu sehen ist, war die Anpassung der genetischen Operatoren bezüglich der Geschwindigkeit und der Wahrscheinlichkeit (Menge zulässiger Design) erfolgreich. Das Best_Design konnte in Generation 28 (Design_2717) mit einem Gewicht von 1148 kg und einem Bauraum von $3.38e8 \text{ mm}^4$ gefunden werden. Insgesamt konnten 1018 zulässige Design gefunden werden. Weil sich die genetische Optimierung auf die Inselfsuche konzentriert, ist das Gewichtsniveau der zulässigen Designs allerdings noch sehr hoch (1150 kg).

Im Plot der Historie der Zielfunktion (nur Einfluss Gewicht und Bauraum) ist zu sehen, dass die gewählte genetische Strategie mit gutem Trend Inseln findet. Das erste zulässige Design konnte im Run 1219 mit 1148 kg gefunden werden. Ab ca. Generation 30 nimmt die Varianz in der Zielfunktion allerdings deutlich zu. Hier erzeugt die gewählte genetische Strategie bezüglich einer Gewichtsreduktion zuviel Mutation. In der Folge ist nur ein schwacher Trend zur Verbesserung zu erkennen.

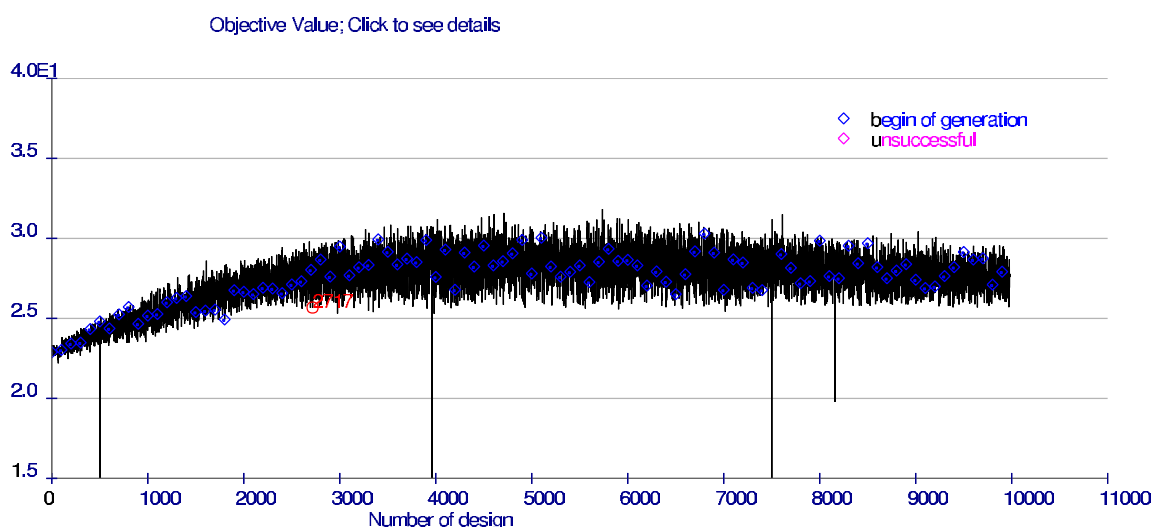


Abbildung 8: Historie der Zielfunktion

3.3 Clusteranalyse und lokale Optimierung

Mit Clusteranalyse werden aus dem Unterraum der 1018 zulässigen Design 10 Cluster ermittelt. Dabei werden die Cluster in Abhängigkeit von einem Radius im normierten Raum gesucht. Der Clusterschwerpunkt wird dabei von zwei ähnlichsten Design jedes Cluster gebildet. Der Clusteralgorithmus ermittelt dabei aus der Menge der zulässigen Design die beiden ähnlichsten Designs und ermittelt dann alle Design, die im Clusterradius liegen. Diese Designs bilden den Cluster 1. Im verbleibenden Raum der zulässigen Design wird mit analoger Vorgehensweise der Cluster 2 und alle weiteren Cluster gesucht. Weil die Zugehörigkeit zum Cluster vom Clusterradius abhängig ist, wird die Clusterbildung mit schrittweise größerem Radius solange wiederholt, bis die Cluster zusammenfallen. Damit wird iterativ der größtmögliche Clusterradius zur kleinstmöglichen Aufteilung der

zulässigen Designs in Cluster ermittelt. In der Folge werden von 10 ausgewählten Design lokale Optimierungen mittels gradientenbasierter Optimierung gestartet. Als Startpunkt für den Gradientenoptimierer wird jeweils das Design aus dem Cluster selektiert, das am sichersten die Nebenbedingungen erfüllen. Hier wird das größte Potential zur Gewichtsoptimierung vermutet. In der folgenden Tabelle wird die erfolgreichste lokale Optimierung im Cluster 4 ausgewertet. Mittels Clusteranalyse und lokaler Optimierung mit NASTRAN Sol200 konnte ein zulässiges Design mit einem Gewicht von 1056 kg gefunden werden.

	Gewicht [kg]	NB Steifigkeit OptiSLang	NB Eigenfrequenzen OptiSLang	maximale NB NASTRAN
OptiSLang Cluster 4	1160	0.89	0.989	
NASTRAN_Optimierung vom Clusterschwerpunkt 4	1056			1.000

Tabelle 1: Optimierungsergebnisse mit NASTRAN Sol200 im Cluster 4




Abbildung 9: Differenz Bauraum Design_Cluster_4 zu Best_Design_Natran_old

Für die Identifikation alternativer Gesamtfahrzeugkonzepte wurde der normierte Abstand zweier Designvektoren (Vektor der Optimierungsvariablen) bewertet. Weil die lokale Optimierung der Cluster 1 bis 10 diesbezüglich sehr ähnliche Designs erreicht hat, wird davon ausgegangen, dass diese Cluster alle zu einer Konstruktionsvariante gehören und damit im Sinne einer Inseldefinition von Konstruktionsvarianten alle auf einer Insel liegen. Deshalb wird die Clusteranalyse fortgesetzt und der Clusterradius, solange erhöht, bis die ersten 10 Cluster zusammenfallen und sich 10 neue stabile Cluster bilden. Diese Cluster werden als

Cluster 11-20 bezeichnet und es wird wiederum pro Cluster eine lokale Optimierung mit NASTRAN Sol200 durchgeführt. Als Startwerte der lokalen Optimierung wurde wiederum das Design im Cluster ausgewählt, welches die Nebenbedingungen am sichersten erfüllt.

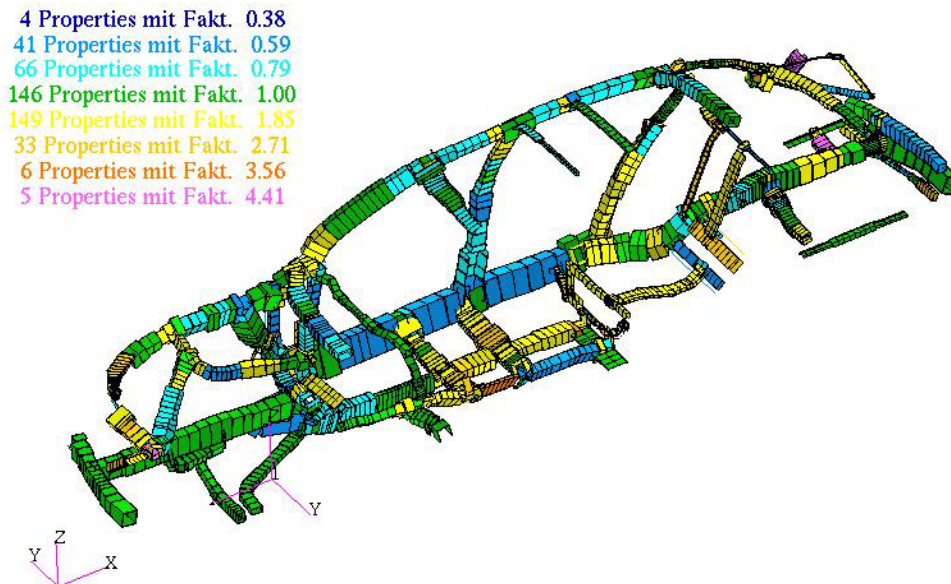


Abbildung 10: Differenz Gewicht Design_Cluster_4 zu Best_Design_Natran_old

Mittels gradientenbasierter Optimierung konnte im Cluster 11 ein zulässiges Design mit einem Gewicht von 1037 kg gefunden werden. In Tabelle 2 ist die Optimierung im Cluster 11 zusammengestellt. Ein Vergleich der normierten Abstände der optimalen Designs aller 20 Cluster und des bisher besten Design einer konventionellen NASTRAN Sol200 Optimierung ergab große Entfernungen der optimierten Designs im Designraum und es wird davon ausgegangen dass die Designs zu unterschiedlichen Konstruktionsvarianten gehören. Die Abbildungen 13 und 14 zeigen die Unterschiede der beiden Konstruktionsvarianten.

	Gewicht [kg]	NB Steifigkeit OptiSLang	NB Eigenfrequenzen OptiSLang	maximale NB NASTRAN
OptiSLang Cluster 11	1167	0.868	0.983	
NASTRAN_Optimierung vom Clusterschwerpunkt 11	1037			1.000

Tabelle 2: Optimierungsergebnisse mit NASTRAN Sol200 im Cluster 11

3 Properties mit Fakt. 0.37
 9 Properties mit Fakt. 0.58
 27 Properties mit Fakt. 0.79
 127 Properties mit Fakt. 1.00
 241 Properties mit Fakt. 2.21
 30 Properties mit Fakt. 3.42
 8 Properties mit Fakt. 4.63
 5 Properties mit Fakt. 5.84




Abbildung 11: Differenz Bauraum Design_Cluster_11 zu Best_Design_Natran_old

7 Properties mit Fakt. 0.36
 41 Properties mit Fakt. 0.57
 91 Properties mit Fakt. 0.79
 159 Properties mit Fakt. 1.00
 136 Properties mit Fakt. 2.25
 13 Properties mit Fakt. 3.50
 1 Properties mit Fakt. 4.75
 2 Properties mit Fakt. 6.00




Abbildung 12: Differenz Gewicht Design_Cluster_11 zu Best_Design_Natran_old

4 Zusammenfassung der hybriden Optimierung

Gegenüber der bisherigen Vorgehensweise konnte im Vorentwurf mit hybrider Optimierung rund 60 kg Gewicht (5 % des Gesamtgewichtes) eingespart werden.

Im Vergleich zwischen den gewichtsoptimierten Design der ersten 20 Cluster konnten bezüglich des verwendeten Ähnlichkeitskriteriums alternativer Gesamtfahrzeugkonzepte deutlich unterschiedliche zulässige gewichtsmäßig interessante

Designs identifiziert werden. Damit konnten gewichtsmäßig interessante zulässige Designs gefunden werden, die zu unterschiedlichen „Designinseln“ (Konstruktionsvarianten) im Designraum gehören. So ist in den Designs aus Bild 13/14 zu erkennen, dass der Bauraum im Heck sowie das Gewicht im Heck, der C-Säule, der Dachquerträger sowie und Bodenlängs- und Bodenquerträger zum Teil deutlich unterschiedlich sind.

12 Properties mit Fakt. 0.43
 37 Properties mit Fakt. 0.62
 31 Properties mit Fakt. 0.81
 131 Properties mit Fakt. 1.00
 221 Properties mit Fakt. 3.57
 12 Properties mit Fakt. 6.13
 1 Properties mit Fakt. 8.70
 5 Properties mit Fakt. 11.27




Abbildung 13: Differenz Bauraum Design_Cluster_4 zu Design_Cluster_11

25 Properties mit Fakt. 0.31
 58 Properties mit Fakt. 0.54
 46 Properties mit Fakt. 0.77
 116 Properties mit Fakt. 1.00
 193 Properties mit Fakt. 2.52
 8 Properties mit Fakt. 4.03
 3 Properties mit Fakt. 5.55
 1 Properties mit Fakt. 7.06




Abbildung 14: Differenz Gewicht Design_Cluster_4 zu Design_Cluster_11

5 Ausblick

Das bisherige Erfolgsrezept lässt sich wie folgt zusammenfassen:

- Verwendung eines Repairscripts, welches alle Vorschläge des Optimierer auf Konstruktionsrandbedingungen prüft und die Designs repariert. Das reparierte Design wird dann vom Optimierer wieder eingelesen und verwendet.
- Globale Optimierung (Inselsuche) mit genetischen Suchstrategien in OptiSLang mit Hilfe einer Startgeneration, die mit Wissen der Hierarchie um das Referenzdesign erzeugt wird und in einen Gewichtsraum vom erwarteten Optimum skaliert wird.
- Nachdem eine ausreichende Anzahl zulässiger Designs gefunden wurde, werden mittels Clusteranalyse geeignete Startpunkte der lokalen Optimierung bestimmt.
- Die lokale Optimierung (Gewichtsoptimierung) auf den Inseln zulässiger Designs wird mittels eines Gradientenoptimierer durchgeführt.

Insgesamt werden rund 13000 Designevaluierungen (Rechenzeit ca. 2-3 Tage) mit OptiSLang zur Inselsuche benötigt. Danach werden ca. 20 lokale Optimierungen mittels NASTRAN Sol 200 durchgeführt.

Nachdem durch die Kombination von Samplingstrategien, genetischer Optimierung zur globalen Inselsuche, Clusteranalyse zur Identifikation von Inseln unterschiedlicher Designbereiche und Gradientenoptimierung zur lokalen Gewichtsoptimierung eine signifikante Gewichtsreduktion erreicht werden konnte, steht in einer weiteren Projektstudie die Robustheit des Gesamtprozesses und die weitere Verbesserung der Performance aller Teilschritte im Vordergrund. Zuzüglich wird der Gesamtprozess als vordefinierter Flow in eine BMW-Version der GUI Umgebung von OptiSLang integriert.

References

- [1] OptiSLang - the Optimizing Structural Language Version 2.0, DYNARDO, Weimar, 2004, www.dynardo.de
- [2] Bucher C. et al.: SLang - the Structural Language Version 5.0, Institute of Structural Mechanics - Bauhaus-University Weimar, 2004.
- [3] Will, J., Bucher, C., Riedel, J., Akgün, T. „Stochastik und Optimierung: Anwendungen genetischer und stochastischer Verfahren zur multidisziplinären Optimierung in der Fahrzeugentwicklung“; VDI-Berichte, Nr. 1701, 2002, S. 863-884