

Vorträge

**Kombination von Optimierung
und Robustheitsbewertung aus
praktischer Sicht**

Johannes Will

Kombination von Optimierung und Robustheitsbewertung aus praktischer Sicht

Johannes Will

DYNARDO GmbH, Weimar, Germany

Zusammenfassung:

Optimierung und Robustheitsbewertung sind Schlüsseltechnologien virtueller Produktentwicklung. Die Optimierung ist bereits seit einigen Jahren fester Bestandteil virtueller Produktentwicklung. Die Robustheit einer Konstruktion, also die zuverlässige Funktionsweise innerhalb erlaubter Toleranzen, rückt mehr und mehr ins Blickfeld. Im Grund handelt es sich dabei um eine zusätzliche Anforderung an „optimierte“ Designs. Die Optimierung und Robustheitsbewertung kann sowohl gleichzeitig als auch nacheinander, das heißt iterativ, erfolgen. Zahlreiche Methoden stehen dafür zur Verfügung.

Im Folgenden sollen vorhandene Methoden kurz vorgestellt und aus Sicht der praktischen Anwendung in virtuellen Produktentwicklungsprozessen diskutiert werden. Zur Bearbeitung des Optimierungsproblems werden drei Verfahrensklassen diskutiert: mathematische Optimierungsverfahren mittels Gradienten, Response Surface Methoden und stochastische Suchstrategien. Kurz wird auf Verfahren der Pareto-Optimierung eingegangen.

Mit Hilfe der Robustheitsanalyse wird die Sensitivität unvermeidbarer Streuungen von äußeren Bedingungen und deren Einfluss auf die wichtigsten Strukturantworten bewertet. Besonders im Fall von nichtlinearem Strukturverhalten ist es erforderlich, die Robustheit bezüglich der Streuungen des wichtigsten Entwurfparameter zu analysieren.

Während mittels Robustheitsbewertungen Streuungen um Mittelwerte verbunden mit relative häufigen Ereignissen bewertet werden, müssen zur Absicherung seltener Ereignisse Verfahren der Zuverlässigkeitsanalyse herangezogen werden. Darüber hinaus werden Methoden einer gleichzeitigen Bearbeitung von Optimierungs- und Robustheitsaufgabenstellung kurz vorgestellt. An zwei praktischen Anwendungsbeispielen werden potentielle Einsatzgebiete von Optimierung und Robustheitsbewertungen aufgezeigt.

Keywords:

robustness evaluation, stochastic analysis, optimization

1 Einleitung

Optimierung und stochastische Analyse in Form von Robustheitsbewertung und Zuverlässigkeitsanalyse sind Schlüsseltechnologien virtueller Produktentwicklung. Die Optimierung ist bereits seit einigen Jahren fester Bestandteil virtueller Produktentwicklung. Die Robustheit einer Konstruktion, also die zuverlässige Funktionsweise innerhalb erlaubter Toleranzen, rückt mehr und mehr ins Blickfeld. Sie ist im Grunde eine zusätzliche Anforderung an „optimale“ Designs. Für die notwendige iterative Bearbeitung oder gleichzeitiger Bearbeitung von Optimierung und Robustheitsbewertung bzw. Zuverlässigkeitsanalyse stehen zahlreiche Methoden zur Verfügung. Deren Eignung und deren „Bezahlbarkeit“ (Anzahl notwendiger externe CAE-Solver Auswertungen) sowie im Besonderen deren Zuverlässigkeit in der Prognose ist allerdings nicht a priori gesichert. Hier ist neben erheblicher Rechenpower auch mit einem nennenswerten Integrationsaufwand für eine erfolgreiche Einführung in die bestehenden Produktentwicklungsprozesse zu rechnen. Andererseits ist man sich einig, dass eine Kombination von Optimierung und stochastischer Analyse bei immer kürzeren Entwicklungszyklen zwingend notwendig ist und hier großes Potential für Innovation und Wettbewerbsvorteil erhofft wird.

Im Folgenden sollen Methoden der Optimierung und der Robustheitsbewertung aus Sicht der praktischen Anwendung in virtuellen Produktentwicklungsprozessen kurz vorgestellt und diskutiert werden. Dabei sollen weniger methodische Details als viel mehr Anforderungen, Restriktionen und Anwendungsgebiete diskutiert werden. Für methodische Details wird auf die Literatur verwiesen. Naturgemäß zwingt eine möglichst konkrete und verständliche Bewertung der zahlreichen Algorithmen zu Vereinfachungen und Konzentration auf bisher erfolgreiche Anwendungen. Mittels hybrider Ansätze oder Spezialisierungen und Erweiterungen einzelner Methoden werden die Grenzen der Anwendungsgebiete dieser Methoden sicherlich verschiebbar. Es ist allerdings auch in naher Zukunft davon auszugehen, dass nicht ein einzelner Algorithmus zur Verfügung steht, der die Mehrheit der Optimierungs- und Zuverlässigkeitsaufgabenstellungen effektiv, also wirtschaftlich, und zufrieden stellend lösen kann.

2 Optimierung

Für Optimierungsaufgabenstellungen wird der Variationsraum oder Designraum durch Optimierungsvariablen definiert. Diese können kontinuierliche Werte zwischen unterer und oberer Grenze oder diskrete Zustände annehmen. Gewünschte Eigenschaften eines „optimalen“ Designs werden mittels Nebenbedingungen und Zielfunktionen definiert. Optimierungsverfahren durchsuchen dann den Designraum auf eine möglichst gute Annäherung an Nebenbedingungen und Zielfunktion. Werden dabei mehrere Berechnungsdisziplinen gleichzeitig bearbeitet, spricht man von multidisziplinärer Optimierung. Werden mehrere Zielfunktionen definiert, spricht man von multikriterieller Optimierung. Zur Bearbeitung des Optimierungsproblems stehen grundsätzlich mindestens drei Verfahrensklassen zur Auswahl: mathematische Optimierungsverfahren mittels Gradienten (Gradientenverfahren), Response Surface Methoden (RSM) und stochastische Suchstrategien.

2.1 Mathematische Optimierungsverfahren mittels Gradienteninformationen

Mathematische Optimierungsverfahren [11,12], welche mittels Gradienteninformationen Suchrichtungen ermitteln, bieten von allen oben genannten Verfahren das beste Konvergenzverhalten zum Optimum. Sie stellen aber auch die höchsten Anforderungen an die mathematische Beschaffenheit der numerischen Problemformulierung, an Stetigkeit, Differenzierbarkeit, Glattheit, Skalierbarkeit sowie an die Genauigkeit der Gradientenbestimmung.

Am kritischsten aus praktischer Sicht ist eine Nichtverfügbarkeit analytischer bzw. semianalytischer Gradienten gegenüber wichtigen zu bewertenden Ergebnisgrößen bzw. die Unbrauchbarkeit numerischer Gradienten zum Beispiel bei verrauschten Problemstellungen, nicht differenzierbaren Problemstellungen oder Genauigkeitsproblemen bei der Bestimmung numerischer Gradienten. Ein erfolgreicher praktischer Einsatz konzentriert sich folgerichtig auf Optimierungsprobleme mit kontinuierlichen Optimierungsvariablen, mit mathematisch geeigneten Problemformulierungen bei denen geeignete Gradienten berechnet werden können, wie zum Beispiel lineare/nichtlineare implizite FEM. Gradientenverfahren sollten dabei möglichst in zulässigen Designbereichen, in denen die Nebenbedingungen erfüllt sind, starten. Um lokale Optima zu identifizieren sollten sie von verschiedenen Startpunkten ausgeführt werden.

2.2 Response Surface Methoden

Wenn mathematische Optimierungsverfahren nicht erfolgreich sind und die Anzahl der Optimierungsvariablen auf wenige Variablen (5...15) begrenzt werden kann, bieten Response Surface

Methoden [6] attraktive Optimierungsmöglichkeiten. Diese Methoden erzeugen mittels Approximationsfunktionen auf einem geeigneten Set von Stützstellen (Stichproben des Variablenraumes) eine Approximation des Designraumes. Die Stützstellen sollten dabei mit auf die verwendeten Approximationsfunktionen optimalen Stützstellenmustern (Design of Experiments –DOE) ermittelt werden. Die Approximationsfunktionen haben in der Regel gute mathematische Eigenschaften, so dass zur Suche des Optimums im Ersatzraum mathematische Optimierungsverfahren eingesetzt werden.

Achillesverse der Response Surface Methoden ist der Nachweis, dass die Approximation an interessanten Stellen des Designraumes brauchbar bzw. für die Optimierung genau genug ist. Zur Sicherung der Approximationsgüte werden Adaptionsschemen verwendet. Hierbei sind adaptive Response Surface Methoden, die den Approximationsraum solange zoomen und verschieben bis das Optimum auf der Response Surface konvergiert, am erfolgreichsten [13].

Die kritische Größe aus Sicht praktischer Anwendung ist vor allem die Anzahl der Optimierungsvariablen. Heute werden adaptive Response Surface Methoden erfolgreich zum Beispiel bei verrauchten Problemstellungen (explizite FEM/MKS, Crash) mit bis ca. 15 Optimierungsvariablen eingesetzt.

2.3 Evolutionäre Suchstrategien

Führen die zuvor genannten Verfahrensklassen nicht zum Ziel, verbleiben zur Bearbeitung der Problemstellung stochastische Suchverfahren, von denen evolutionäre Verfahren mit den Untergruppen genetische Algorithmen [5] und evolutionäre Strategien [9] am erfolgreichsten sind. Der Begriff stochastische Suchverfahren wird hier verwendet, weil „zufällige“ Ereignisse zur Designveränderung führen.

Weil stochastische Suchstrategien gegenüber mathematischen Optimierungsverfahren eine wesentlich schlechtere Konvergenz in der Nähe des Optimums aufweisen und eine sehr große Anzahl von Designevaluationen zur Konvergenz benötigen, wird oft von einer Designverbesserung und nicht von einer Optimierung gesprochen.

Wichtiges Unterscheidungsmerkmal zwischen genetischen Algorithmen und evolutionären Strategien ist die Art und Weise der evolutionären Entwicklung der Optimierungsvariablen. Wichtigster Evolutionsprozess genetischer Algorithmen ist der zufällige Austausch von Genen (Optimierungsvariablen) zwischen zwei Elterndesigns zur Erzeugung der Nachkommen. Wichtigster Evolutionsprozess evolutionärer Suchstrategien ist die Mutation (zufällige Änderung) einzelner Gene eines Elterndesigns zur Erzeugung eines Nachkommen.

Genetische Algorithmen eignen sich dabei besonders gut für eine relativ weiträumige Durchsuchung des Designraumes. Deshalb werden sie häufig für die Suche verschiedener Designgebiete ähnlich guter Performance (Inselsuche) [17] oder für eine Designverbesserung ohne in die Evolution eingeführtes Vorwissen eingesetzt. Evolutionäre Strategien eignen sich besonders gut für eine Designverbesserung „voroptimierter“ Designinseln oder Konstruktionsstände mit in die Startgeneration oder in die Evolutionsoperatoren integriertem Vorwissen.

Mit Mischformen, selbstregelnden oder adaptiven Evolutionsstrategien lassen sich die Vorteile genetischer und evolutionärer Strategien verknüpfen und die Designverbesserung beschleunigen.

2.4 Sensitivitätsstudien

Wie die bisherige Diskussion zeigt, ist das Wissen um die Eigenschaften des Variationsraums wichtig für die Wahl einer geeigneten Optimierungsmethode aber auch für die Formulierung der Nebenbedingungen und Zielfunktionen. Ist ein solches Vorwissen nicht vorhanden, werden Sensitivitätsstudien empfohlen.

Parameterstudien, also die Variation einzelner Parameter, gehören seit langem zum Ingenieuralltag. In Analogie dazu können in kleinen Parameterräumen Design of Experiments Methoden, die systematisch einzelne Parameter und Parameterkombination berechnen, verwendet werden. Nimmt die Dimension oder die Nichtlinearität des Parameterraumes zu, sind stochastische Samplingstrategien zur Erzeugung des Stützstellensets zu bevorzugen.

Ein zusätzlicher Vorteil der stochastischen Samplingstrategien im Vergleich zum Design of Experiments ist, dass sie darüber hinaus eine statistische Bewertung in Form von Korrelations- und Variationsanalysen der Sensitivitäten im Variationsraum erlauben.

Mittels Sensitivitätsstudien können dann zum Beispiel instabile Bereiche im Designraum, Hinweise auf die Variationspotentiale der Ergebnisgrößen oder globale Korrelationsstrukturen (welche Optimierungsvariablen wirken wie auf welche Ergebnisgrößen) identifiziert werden. Damit ermöglichen Sensitivitätsstudien gegebenenfalls eine Reduktion des Parameterraumes für anschließende Optimierungsaufgabenstellungen. Das Vorwissen aus den Sensitivitätsstudien über Eigenschaften

des Designraumes ist darüber hinaus häufig für eine geeignete Formulierung von Nebenbedingungen und Zielfunktionen sehr hilfreich.

2.5 Pareto Optimierungsstrategien

Es ist schon darauf hingewiesen worden, dass Optimierungsprobleme mehrere Zielkriterien (multikriterielle Optimierung) besitzen können.

Sind diese Kriterien nicht in Konflikt, können Wichtungsstrategien zum Zusammenfassen mehrerer Kriterien zu einer Zielfunktion verwendet werden. Verschiedene Wichtungen der Einzelkriterien wirken dann aus mathematischer Sicht „nur“ auf die Konvergenzgeschwindigkeit derselben. Aus praktischer Sicht können allerdings auch im Falle nicht in Konflikt stehender Zielkriterien unterschiedliche Wichtungen zu unterschiedlichen Optimierungsergebnissen führen. Ursachen hierfür können lokale Optima, „flache“ optimale Bereiche oder nicht konvergierte Zustände sein.

Stehen einzelne Zielkriterien in Konflikt, existiert schon aus mathematischer Sicht nicht mehr ein Optimum. Stattdessen existiert eine Menge „optimaler“ Kompromisslösungen. Dann bestimmen die Wichtungen der einzelnen Zielkriterien in noch stärkerem Maße den „optimalen“ Kompromiss.

Alternativ können zur Bestimmung der Kompromissmenge Verfahren der Pareto Optimierung eingesetzt werden. Das erlaubt dem Bearbeiter mittels a posteriori Wichtung im Nachgang und nicht vor Beginn der Optimierung die optimale Kompromisslösung auszuwählen. Erfolgreiche Verfahren der Pareto Optimierung verwenden in der Regel evolutionäre Strategien wie zum Beispiel Strength Evolutionary Pareto Algorithmen [18].

Erfolgreiche praktische Anwendungen begrenzen sich auf zwei und drei-dimensionale multikriterielle Aufgabenstellungen. Dabei sind weniger die zu Grunde liegenden Algorithmen selbst auf zwei bis drei Dimensionen beschränkt als die Möglichkeiten, die Kompromisslösung geeignet darzustellen. Eine solche Darstellung ist aber für eine a posteriori Auswahl unerlässlich.

Wenn nicht mehr ein optimaler Punkt, sondern eine Menge optimaler Punkte bestimmt werden sollen, ist nicht verwunderlich, dass der Berechnungsaufwand in der Regel nennenswert ansteigt. Das legt nahe, dass Pareto Optimierungsstrategien nicht am Anfang einer Bearbeitung der Optimierungsaufgabenstellung stehen sollten. Sie haben ihre Berechtigung, wenn die Struktur des Optimierungsproblems (wichtige Eingangsgrößen und wichtige Nebenbedingungen) gut bekannt ist und sicher ist, dass zwei oder drei wichtige Zielkriterien in Konflikt stehen.

3 Robustheitsbewertung

Zur Einführung des Begriffes der Robustheitsbewertung soll in sehr verkürzter Art und Weise das Konzept stochastischer Berechnungsmethoden wiedergegeben werden.

3.1 Stochastische Berechnungsmethoden

In den bisherigen Ausführungen wurde vom rein deterministischen Konzept ausgegangen. Dieses berücksichtigt keinerlei Unsicherheiten (Streuungen) und damit nur einen möglichen Zustand des Designs sowie der Randbedingungen und Lasten beschreibt, analysiert und als Bewertungsgrundlage heranzieht. Im Sinne stochastischer Methoden entspricht das einer Analyse mit Mittelwerten (Erwartungswerten). Wenn Streuungen um diese Mittelwerte der Eingangsgrößen sowie auch die resultierende Streuungen wichtiger Antwortgrößen klein sind, beschreibt eine deterministische Analyse die Problemstellung ausreichend genau.

Wenn aber das Wissen um Widerstände beziehungsweise von Lasten unsicher oder mit großen Streuungen behaftet ist, oder ein nichtlineares Übertragungsverhalten der Streuungen zu Ergebnisgrößen außerhalb von Toleranzbereichen führt, muss der Einfluss streuender Eingangsgrößen untersucht werden.

Das haben Ingenieure natürlich auch schon vor der Einführung stochastischer Berechnungskonzepte zum Beispiel mittels Variantenstudien oder worst case Szenarien berücksichtigt. Angesichts immer komplexer werdender Berechnungsmodelle und immer höher werdender Anforderungen an Qualität und Zuverlässigkeit und nicht zuletzt aus ökonomischen Zwängen werden jedoch quantitative Bewertungen der Streuung mittels stochastischer Berechnungsmethoden erforderlich. Quantitativ meint in diesem Zusammenhang, dass über die in Natura vorhandenen Streuungen auf der Eingangsseite ein Basiswissen vorhanden sein muss, das in Verteilungsfunktionen statistisch beschrieben wird. Mittels stochastischer und statistischer Berechnungsverfahren wird daraus die Streuung in den Ergebnisgrößen oder die Wahrscheinlichkeit von Ereignissen im Ergebnisraum geschätzt.

Grundsätzlich hängt dabei das erreichbare Genauigkeitsniveau, hier das erreichbare Wahrscheinlichkeitsniveau im Ergebnisraum, von der Genauigkeit des Wissens um die Eingangsgrößen, in diesem Fall die Kenntnis der Verteilungsfunktionen, ab. Das heißt, sollen Ereignisse mit einer Wahrscheinlichkeit von 5% ausgeschlossen werden, reichen schon relativ grobe Kenntnisse der vorhandenen Unsicherheiten und Streuungen der Eingangsvariablen. Möchte man seltenere Ereignisse (1 von einer Million) absichern, wird wesentlich exakteres Wissen um Eingangsstreuungen benötigt.

Zusätzlich muss die gewählte stochastische Berechnungsmethode eine gewünschte Genauigkeit der Schätzung der statistischen Größen gewährleisten können. Während der Berechnungsingenieur bei der deterministischen Optimierung das erreichte Ergebnis seinen bisherigen Bewertungsmaßstäben unterziehen kann, so entziehen sich die statistischen Maße stochastischer Berechnungen häufig herkömmlichen Bewertungsstrukturen. Obige Gründe legen nahe, dass die Einführung stochastischer Analysen in virtuelle Produktentwicklungsprozesse mit Robustheitsbewertungen [16] beginnen sollte.

Die Ergebnisse von Robustheitsbewertungen sollten in Übereinstimmung mit Erfahrungswerten und Versuchsergebnissen gebracht werden, die zugrunde liegenden Übertragungsmechanismen der Streuungen müssen nachvollzogen werden. Robustheitsbewertungen können dann ein erster Schritt zu stochastischen Berechnungen sein. Relativ grobes Wissen um vermutete Streuungen der Eingangsgrößen ermöglicht die Ermittlung von deren Sensitivität auf die Streuung der Ergebnisgrößen. Robustheitsbewertungen bewerten dann in aller Regel Streuungen um Mittelwerte der Eingangsgrößen und deren Einfluss auf die Streuung der Ergebnisgrößen, und sichern gleichzeitig relativ häufige Ereignisse (Auftrittswahrscheinlichkeit im Prozentbereich) ab.

Sollen seltenere Ereignisse abgesichert werden, werden Verfahren der Zuverlässigkeitsanalyse notwendig. Diese schätzen kleine Wahrscheinlichkeiten mittels Approximationen der Grenzzustandsfunktion (FORM/SORM [8]), durch spezielle Samplingstrategien (adaptive sampling [2], directional sampling [4]) oder durch eine Kombination aus beiden (ISPUD [1]). Weil die Verfahren der Zuverlässigkeitsanalyse häufig nur in kleinen Parameterräumen bezahlbar sind, sind Robustheitsbewertungen oft eine notwendige Vorstufe um diese Parameterräume zu reduzieren. Es sei darauf hingewiesen, dass für Zuverlässigkeitsaussagen kleiner Ereigniswahrscheinlichkeiten in aller Regel ein wesentlich größerer Berechnungsaufwand notwendig wird und die Verteilungsfunktionen der streuenden Eingangsgrößen wesentlich genauer bekannt sein sollten.

3.2 Robustheitsbewertungen

Robustheitsbewertungen können auch als Sensitivitätsanalysen der Streuung der Antwortgrößen gegenüber Streuungen um Mittelwerte der Eingangsgrößen bezeichnet werden. Neben der Schätzung der Streuung der Antwortgrößen identifizieren Robustheitsbewertungen die dafür verantwortlichen streuenden Eingangsgrößen und können relativ häufige Ereignisse mit Auftretenswahrscheinlichkeiten im Prozentbereich absichern.

Im Unterschied zu den Sensitivitätsanalysen in Variationsräumen, die im Abschnitt 2.4 vorgestellt wurden, werden die Streuungen der Eingangsgrößen nicht mit unterer und oberer Variationsgrenze beschrieben. Bei Robustheitsbewertungen kommen hierfür Verteilungsfunktionen zum Einsatz, die die in Natura vorhandenen vermuteten Streuungen um die Mittelwerte repräsentieren. Mittels Samplingverfahren werden eine Anzahl möglicher Designevaluierungen erzeugt. Im Nachgang werden zur quantitativen Bewertung der Streuung der Antwortgrößen Mittelwerte, Variationskoeffizienten und Verteilungsfunktionen in den Histogrammen der Antwortgrößen geschätzt. Zur Ermittlung der Korrelationsstrukturen werden Korrelationskoeffizienten bestimmt und eine Principal Component Analyse (PCA) durchgeführt. Die linearen Korrelationskoeffizienten bewerten den linearen Zusammenhang zwischen der Variation von zwei Variablen, also einer Inputgröße zu einer Antwortgröße. Dagegen werden mit Hilfe einer Principal Component Analyse der linearen Korrelationsmatrix höherdimensionale Korrelationen, d.h. die Auffälligkeiten von Korrelationen einer Gruppe von Inputvariablen zu einer Gruppe von Antwortvariablen, untersucht. Neben solchen höherdimensionalen Informationen über Korrelationen zerlegt die Principal Component Analyse die lineare Korrelationsstruktur in die einzelnen Übertragungsmechanismen der Streuungen und erlaubt dadurch dem Ingenieur gegebenenfalls die Zerlegung des Problems in mehrere Unterräume.

Die Anzahl der Stützstellen sollte in Abhängigkeit der statistischen Maße gewählt werden, welche ausgewertet werden sollen. Grundsätzlich stehen dabei Monte Carlo Sampling oder Varianten des Latin Hypercube Sampling zur Verfügung. Weil mittels Latin Hypercube Sampling wesentlich weniger Stützstellen zum Erreichen vergleichbarer Vertrauensintervalle der statistischen Größen als mit Monte Carlo Sampling erforderlich sind, sind Latin Hypercube Samplings zu bevorzugen.

Für eine statistische Bewertung der Einzelgrößen (Mittelwert, Histogramm, Variationskoeffizient) wird für Latin Hypercube Verfahren eine Mindeststichprobenanzahl von $2 \cdot (\text{Anzahl der zufälligen Responsegrößen})$ empfohlen. Für eine statistische Absicherung der linearen Korrelationsstruktur wird

mindestens eine Stichprobenanzahl von $2 \cdot (\text{Eingangs- und Antwortgrößen})$ empfohlen. In kleinen Dimensionen (d.h. weniger als 20 Eingangs- und Antwortgrößen), bei stark nichtlinearen oder verrauschten Problemen kann die notwendige Anzahl für eine Ermittlung der linearen Korrelationskoeffizienten obige Mindestanzahl deutlich übersteigen. Deshalb werden für wichtige Korrelationskoeffizienten Konvergenzbetrachtungen empfohlen. Eine genauere Abschätzung der notwendigen Stützstellenanzahlen ist unter Vorgabe der Größenordnung der zu ermittelnden Korrelationskoeffizienten, des angestrebten Vertrauensniveaus und des angestrebten Toleranzintervalls möglich.

3.3 Kombination von Optimierung und Robustheitsbewertung

Am Anfang der Einführung von Optimierung und Robustheitsbewertungen in die virtuellen Produktentwicklungsprozesse wird sehr wahrscheinlich eine iterative Bearbeitung stehen. Dabei werden für optimierte Designs Robustheitsbewertungen durchgeführt. Wird hier hinsichtlich der Robustheit Verbesserungspotential erkannt, kann das Rückwirkungen auf die Optimierungsaufgabenstellung haben. Im einfachsten Fall werden zuvor optimierte Variablen in robustere Bereiche verschoben.

Im Sinne einer möglichst vollständigen Optimierungsaufgabenstellung kann es aber auch zu einer Verschmelzung von Optimierung und stochastischer Analyse kommen. Hierbei erweitert sich die Optimierungsaufgabenstellung um die Minimierung von Streuungen wichtiger Ergebnisgrößen. Abhängig vom Wahrscheinlichkeitsniveau kann in zwei Verfahrensklassen der stochastischen Optimierung [10] unterschieden werden.

Werden Varianzen minimiert, können Methoden der Robust Design Optimization angewendet werden, welche in der Regel Response Surface Approximationen der deterministischen Optimierungsvariablen, der streuungsbehafteten Optimierungsvariablen sowie weiterer streuender Designvariablen, z.B. Randbedingungen oder Lasten, miteinander verknüpfen.

Es sei angemerkt, dass die Response Surface Approximationen für die Varianzschätzung anderen Anforderungen genügen müssen, als die Response Surface Approximationen, die für die Optimierungsaufgabenstellung genutzt werden. Eine zu starke Glättung des Antwortraumes führt im Zweifelsfall zu viel kleineren Varianzschätzungen auf der Response Surface im Vergleich zum realen Designraum. Folgerichtig werden Response Surface Approximationen bevorzugt, die lokale Informationen erhalten können (Krigin Modelle, weighted radii, moving least square Ansätze). Hauptrestriktion der Nutzung von Response Surface Methoden für die praktische Anwendung ist wiederum die relativ kleine Anzahl möglicher Variablen, wobei hier Optimierungs- und streuende Variablen zusammengefasst werden müssen.

Es liegt also auch hier auf der Hand, dass Konflikte zwischen Optimierung und Robustheit bekannt sein sollten und häufig eine Reduktion der Parameterräume mittels Sensitivitätsanalysen und Robustheitsbewertungen notwendig sind. Es ist empfehlenswert, für finale Designs von virtuellen Produktentwicklungsprozessen Robustheitsbewertungen mittels Samplingverfahren im originalen Designraum durchzuführen. So kann überprüft werden, ob die Schätzung der Varianz auf Response Surfaces der Varianz im originalen Designraum entspricht,

Werden Ereigniswahrscheinlichkeiten in die Optimierungsaufgabenstellung integriert, spricht man von zuverlässigkeitsbasierter Optimierung. Neben Response Surface Methoden stehen hierfür gradientenbasierte Methoden (FORM/SORM) zur Verfügung. Es sei darauf hingewiesen, dass bei der Verwendung von Response Surface Methoden für die Ermittlung von (häufig sehr kleinen) Ereigniswahrscheinlichkeiten die Grenzzustandsfunktion approximiert werden sollte [3].

In einigen Fällen sind weder Response Surface Methode noch gradientenbasierte Methoden anwendbar, weil es einerseits nicht möglich ist, in beiden Räumen (Optimierungsvariablen und streuende Variablen) geeignete Gradienten zu gewinnen, und andererseits die Anzahl von Optimierungsvariablen und streuenden Variablen die kritische Anzahl für Response Surface Methoden überschreitet. Dann verbleiben zur Bearbeitung Kombinationen stochastischer Verfahren und Optimierungsverfahren, beispielsweise genetischer Optimierung für die Optimierungsvariablen und FORM für die stochastischen Variablen.

Das bedeutet allerdings einen weiteren Anstieg des notwendigen Berechnungsaufwandes. Häufig lassen diese Verfahren nur noch eine kleine Anzahl von Parametern zu oder führen zu einem exorbitanten Anstieg der Anzahl notwendiger externer CAE-Solver Auswertungen. Für alle Problemstellungen mit nennenswerten externen CAE Durchlaufzeiten stehen automatische Kombinationen von Optimierung und stochastischer Analyse daher sicherlich am Ende eines langen Weges.

4 Anwendungen

In der Folge sollen an zwei praktischen Anwendungsbeispielen potentielle Einsatzgebiete von Optimierungsverfahren und Robustheitsbewertungen aufgezeigt werden. In beiden Anwendungen wurde für die Optimierung und Robustheitsbewertung die Software OptiSLang [7] verwendet.

4.1 Optimierung und Robustheitsbewertung eines Rückhaltesystem

Innerhalb eines Verifikationsprojektes von Methoden der Optimierung und Robustheitsbewertungen wurden für ein Rückhaltesystem Optimierungen der Parameter Gurtkraft, Laufkraft und Venthole durchgeführt. Dabei sollte die erreichbare Anzahl von Sternen bei einer Euro NCAP und US NCAP Bewertung erhöht werden. Da der Ergebnisraum der Mehrkörpersimulation verrauscht war, kamen genetische Optimierungsstrategien und adaptiven Response Surface Strategien zum Einsatz. Beide Strategien ergaben sehr ähnliche „Optima“, wobei adaptive Response Surface Strategien erwartungsgemäß in diesen kleinen Dimensionen eine bessere Konvergenz zeigten.

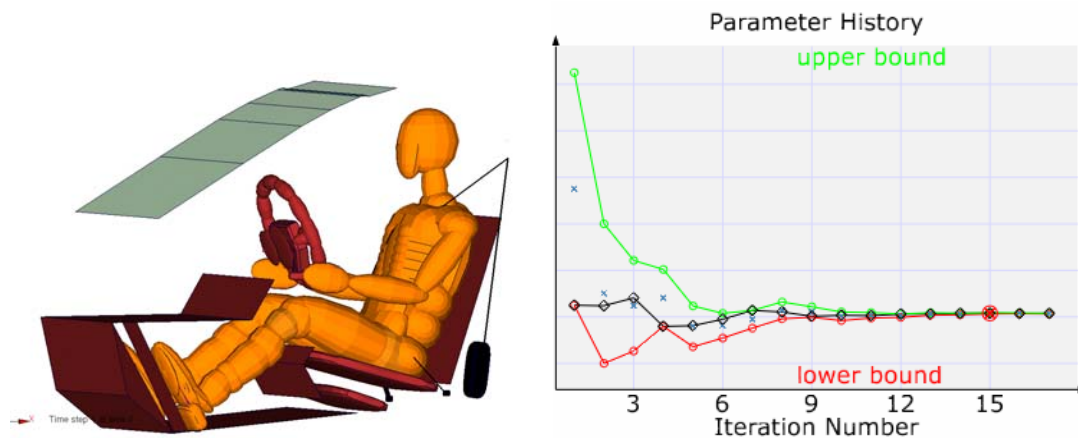


Abb. 1 Rückhaltesystem und Konvergenz der adaptiven Response Surface Methode. Nach zehn adaptiven Response Surface Approximationen waren alle Parameter konvergiert

Eine anschließende Robustheitsbewertung des optimierten Design ergab unter Berücksichtigung von Streuungen der optimierten Variablen sowie von Dummypositionen und Airbagkennwerten Robustheitsprobleme gegenüber der Bewertung nach Euro NCAP. In den Korrelationsstrukturen der Robustheitsbewertung konnte dabei die dafür verantwortlichen streuenden Eingangsvariablen sowie ein Konflikt zwischen der Einstellung der Gurtkraft und den Bewertungen nach Euro NCAP und US NCAP identifiziert werden. Durch eine Verschiebung der Mittelwerte der optimierten Variablen Gurtkraft und Laufkraft konnte ein Design eingestellt werden, das zwar als deterministischer Berechnungslauf eine etwas geringere Performance zeigte, aber bei Berücksichtigung der Streuungen einen besseren Mittelwert mit geringeren Streuungen aufwies.

Im kleinen Optimierungsraum (3 Variablen) wäre eine Pareto-Optimierung zur Ermittlung der Kompromissmenge der Gurtkrafteinstellung bezüglich der erreichbaren Anzahl der Sterne Euro NCAP und US NCAP möglich gewesen. Vorteilhafter erwies sich hier jedoch, weitere Variablen des Rückhaltesystems zur Optimierung freizugeben. In einem Parameterraum mit 11 Variablen konnte der Konflikt bei der Einstellung der Gurtkraft weitestgehend aufgelöst werden und die Performance des Rückhaltesystems konnte erhöht werden.



Abb. 2 Anthillplot Gurtkraft gegenüber Bewertung nach EURO NCAP. Die zwei abfallenden Cluster zeigen zwei Mechanismen des Performanceverlustes an.

4.2 Robustheitsbewertungen des Fahrkomfortverhaltens

Für das Fahrkomfortverhalten von Gesamtfahrzeugmodellen wurden Robustheitsbewertungen durchgeführt [16]. In verschiedenen Lastfällen wurde die Sensitivität einer großen Anzahl von streuenden Variablen untersucht. Zur Beschreibung der streuenden Eingangsgrößen wurden normalverteilte Verteilungsfunktionen aus vorhandenem Wissen möglicher prozentualer Streuungen um die Mittelwerte abgeschätzt. Während der Durchrechnungen wurden die Korrelationsstrukturen (lineare Korrelationsmatrix) beobachtet. Konnte mit zunehmender Anzahl von Durchrechnungen keine nennenswerte Veränderung mehr festgestellt werden, waren die Korrelationsstrukturen zuverlässig bestimmt. Das heißt, die notwendige Samplezahl ist erreicht und die statistischen Maße sind vertrauenswürdig. Erfreulicherweise konnten sehr stabile Korrelationsstrukturen beobachtet werden.

Oft dominieren nur wenige Variablen die Korrelations- und Variationsstrukturen und es können wenige dominierende Nichtlinearitäten im Übertragungsverhalten in den Anthill-Plots identifiziert werden. Damit können die Robustheitsbewertungen zuverlässig die wichtigsten streuenden Eingangsgrößen identifizieren. Gleichzeitig liefern die Robustheitsbewertungen wertvolle Hinweise für die Übertragungswege der Streuungen und zu deren Optimierungspotential.




Abb. 3: FE- Fahrzeugmodell (Explosionsdarstellung)

Im hier dokumentierten Fall werden Robustheitsbewertungen für 76 streuende Lagersteifigkeiten bezüglich der Schalldruckpegel an vier verschiedenen Innenraumpositionen durchgeführt. Dabei werden zwei Motoranregungen untersucht. Berechnet werden insgesamt 199 Stichproben. Die sich ergebenden Korrelations- oder Variationsstrukturen werden von den Steifigkeiten von Motor- und Getriebelager bestimmt. Im ersten Lastfall liegen die Korrelationskoeffizienten der Antwortgrößen zum Getriebelager alle nahe 1.0 und zeigen damit den linearen Zusammenhang der Streuungen aller Ausgangsgrößen zur Streuung des Getriebelagers an.

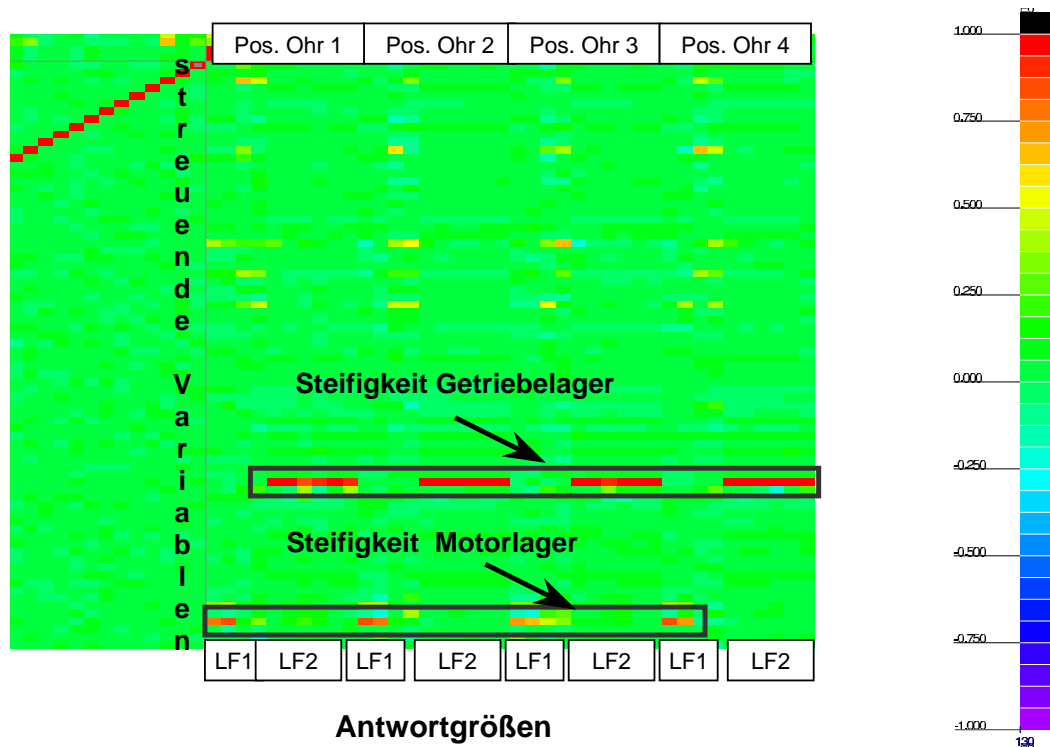


Abb. 4: Lineare Korrelationsmatrix




Abb. 5 Anthill- Plot zwischen Getriebelagersteifigkeit und Antwortgröße

Im zweiten Lastfall liegen die Korrelationskoeffizienten der Antwortgrößen zur Motorlagersteifigkeit zwischen 0.6 und 0.9 und zeigen, dass neben der Motorlagersteifigkeit weitere Eingangsgrößen Einfluss auf die Streuungen der Antwortgrößen haben. Insgesamt ist die Streuung der Schalldruckpegel moderat und unterhalb unerwünschter Amplituden. Durch die Auswertung der Korrelations- und Variationsstrukturen konnten die zwei dominierenden Eingangsvariablen sicher identifiziert werden. Damit können diese zwei Lastfälle über die Variation dieser wenigen Kennwerte deutlich beeinflusst werden.

Komfortpunkt Ohr

Rot
Schwarz

Referenzdesign
199 Robustheitsläufe




Abb. 6: Visualisierung der Streuung des Schalldruckpegels

5 Literature

- [1] U. Bourgund, C. Bucher: „Importance Sampling Procedure Using Design Point (ISPUD) – a Users Manual, Bericht Nr. 8-86, Institut für Mechanik, Universität Innsbruck, 1986
- [2] C. Bucher: “ Adaptive Sampling – An Iterative Fast Monte Carlo Procedure” Structural Safety 5, Nr. 2, 1988
- [3] C. Bucher, M. Macke: “Response Surfaces for Reliability Assesment”; www.dynardo.de
- [4] O. Ditlevsen, P. Bjerager, P. Olesen, R. Hasover: „ Directional Simulation in Gaussian Processes”, Probabilistic Engineering Mechanics 3, 1988, Nr. 4, S. 207-217
- [5] D. E. Goldberg: „Evolution strategies ii: Theoretical aspects”; In Genetic Algorithms in Engineering and Computer Science, chapter 7; Wiley, Chichester, 1995
- [6] H. Myers, C. Montgomery: Response Surface Methodology: Process and Product Optimization Using Designed Experiments”, Wiley, New York, 1995
- [7] OptiSLang - the Optimizing Structural Language Version 2.1, DYNARDO, Weimar, 2004, www.dynardo.de
- [8] R. Rackwitz, B. Fissler: “Structural reliability under combined under combined random load sequences”, Computers and Structures 9, S. 489-494, 1988
- [9] I. Rechenberg: „Evolutionsstrategie '94“; Werkstatt Bionik und Evolutionstechnik Vol. 1; Frommann-Holzboog, Stuttgart, 1994
- [10] D. Roos, C. Bucher: “Methoden der stochastischen Optimierung”; Proceedings Weimarer Optimierungs- und Stochastiktage 1.0, Dezember 2004, Weimar, www.dynardo.de
- [11] K. Schittkowski: “NLPQL A Fortran subroutine solving constrained nonlinear programming problems” Annals of Operation Research; Vol. 5 S. 485-500, 1985/86
- [12] K. Schittkowski, C. Zillober, R. Zotemantel: “Numerical comparison of nonlinear programming algorithms for structural optimization”; Structural Optimization, Vol.7, Nr.1, S. 1-28
- [13] N. Stander, K. Craig: “ On The Robustness of a Simple Domain Reduction Scheme for Simulation-Based Optimization”, Int. Journal for Computer-Aided Engineering and Software, 2002
- [14] J. Unger, D. Roos: “Investigation and benchmarks of algorithms for reliability analysis”, Proceedings Weimarer Optimierungs- und Stochastiktage 1.0, Dezember 2004, Weimar, www.dynardo.de
- [15] J. Will, J-St. Möller, E. Bauer: " Robustheitsbewertungen des Fahrkomfortverhaltens an Gesamtfahrzeugmodellen mittels stochastischer Analyse ", VDI-Berichte Nr. 1846, 2004, S.505-525
- [16] J. Will, C. Bucher: “Robustness Analysis in Stochastic Structural Mechanics”, Proceedings NAFEMS Seminar Use of Stochastics in FEM Analyses; May 2003, Wiesbaden, www.dynardo.de
- [17] J. Will, I. Raasch, C. Bucher, J. Riedel: „Suche nach alternativen Gesamtfahrzeugkonzepten mit OptiSLang“; Proceedings Weimarer Optimierungs- und Stochastiktage 1.0, Dezember 2004, Weimar, www.dynardo.de
- [18] E. Zitzler, L. Thiele: “ An Evolutionary Algorithm for Multiobjective Optimization: The Strength Pareto Approach”; Technical Report 43, Computer Engineering and Communication Networks Lab (TIK); Swiss Federal Institute of Technology (ETH), Zurich, Switzerland, May 1998