

Vorträge

**Robustheitsbewertung in der
stochastischen Strukturmechanik**

Johannes Will, Dirk Roos & Jörg Riedel

Robustheitsbewertung in der stochastischen Strukturmechanik

Johannes Will, Dirk Roos & Jörg Riedel

DYNARDO GmbH, Weimar

Christian Bucher

Institut für Strukturmechanik, Bauhaus-Universität Weimar, Weimar

Summary:

To ensure performance, manufacturability and reliability robustness analysis is an essential component of virtual prototyping analysis cycles. Within the robustness analysis the sensitivity of the unavoidable scatter of environmental conditions and their impact to the most important structural responses is evaluated. Especially for nonlinear structural behavior, when reducing hardware cycles or for optimized designs it is mandatory to analyze the robustness with respect to the most important random variations of the design parameters.

Practical applications, using Latin Hypercube sampling, correlation and principal component analysis show that also high dimensional problems with more than 100 random variables can be handled with manageable CPU-cost. With Robustness analysis the most important random design parameter with their correlations and their impact on the variation behavior of the important responses can be evaluated. Additional system instabilities or cluster behavior can be identified. After identifying the most important design parameter safety and reliability analysis can be performed in reduced parameter dimensions.

Keywords:

Probabilistik, stochastische Analyse, Robustheitsbewertung, Statistik

1 Einleitung

Die durch den weltweiten Konkurrenzdruck notwendigen kürzeren Entwicklungszyklen von immer komplexeren Strukturen bei gleichzeitig steigenden Ansprüchen an Performance, Kosten und Sicherheit lassen sich nur mit konsequentem **virtual prototyping** realisieren. Eine der größten Herausforderungen dabei ist die zunehmende rechnerische Simulation möglichst umfangreicher Test- und Analyseprogramme unter Verwendung von CAE-gestützter Optimierung und CAE-gestützter stochastische Analyse bei gleichzeitiger Minimierung von Hardwareversuchen. Moderne Simulationsverfahren beziehen dabei in immer stärkeren Maße alle verfügbaren Informationen in den Analyseprozess ein und verwenden Optimierung und stochastische Analyse als sich gegenseitig bedingenden und befruchtende Simulationsmethoden [3,4,5].

Bei der Bewertung eines Ingenieur-Designs ist neben möglichst maximierten Performancekriterien die **Robustheit** eines der wichtigsten Kriterien zur Sicherung der Funktionsfähigkeit, Funktionssicherheit und Zuverlässigkeit. Die Robustheit charakterisiert dabei die Empfindlichkeit der Systemantworten gegenüber unvermeidlichen, in Natura vorhandenen Streuungen in den Umweltbedingungen, übertragen auf die Inputvariablen der rechnerischen Simulation.

Können durch Streuungen initiierte kleine Änderungen von Eingangsgrößen signifikant auf die Systemantwort durchschlagen, ist eine rechnerische Robustheitsbewertung unbedingt empfohlen. Für eine Quantifizierung der Funktionsfähigkeit, Funktionssicherheit und Zuverlässigkeit ist dann die Anwendung probabilistischer Berechnungsmethoden zwingend notwendig.

Bei einer rechnerischen Robustheitsbewertung wird dabei mittels stochastischer Analyse ein Sampleset möglicher Realisierungen erzeugt, berechnet und bewertet. Die Streuungen der Inputgrößen werden mittels Verteilungsfunktionen beschrieben. Die Auffälligkeiten in den Streuungen der Systemantworten sowie deren Verknüpfung mit den streuenden Inputvariablen werden mittels statistischer Verfahren auf Korrelations- und Variationseigenschaften untersucht.

Es sei darauf hingewiesen, dass zunehmendes virtual prototyping Selbst die Notwendigkeit stochastischer Berechnungen erhöht. Sollen Hardwareversuche eingespart werden, müssen die im Hardwareversuch noch vorhandenen Streuungen der Randbedingungen (Lasten, Material, Geometrie, u.a.) nun in der Berechnung berücksichtigt werden. Werden die Berechnungen nur für wenige Konfigurationen möglicher Randbedingungen durchgeführt, können keine gesicherten Aussagen über die Robustheit der Systeme und damit über Risiken der Strukturen getroffen werden.

Auch die zunehmende Anwendung der Strukturoptimierung erhöht die Notwendigkeit die Robustheit von „optimierten“ Designs nachzuweisen. Oft führt eine Optimierung von Kosten, Performance und Gewicht zu immer ausgereizteren Strukturen, die bei nichtlinearen Systemen zu erheblichen Robustheitsproblemen führen können. Dass heißt, schon unter kleiner Variation von Inputgrößen sich nennenswerte Änderungen in den Responsegrößen zeigen.

Oft stehen Robustheitsuntersuchungen am Anfang weiterer stochastischer Berechnungen und werden zur Reduktion der Problemdimension im wahrscheinlichkeits-gewichteten Design-Raumes verwendet. Sind die wichtigsten stochastischen Variablen identifiziert, können mit nur wenigen wichtigen streuenden Parametern Berechnungen von Auftretenswahrscheinlichkeiten (Versagen, Überschreitungen) mittels stochastischer Safety and Reliability Analysis [2] (FORM/SORM, Importance Sampling, Directional Sampling) durchgeführt werden.

2 Rechnerische Robustheitsbewertungen

Ziel der Robustheitsbewertung ist es, die **Sensitivität** von streuenden Input-Variablen auf die Streuungen von Systemantworten zu untersuchen. Zur Bewertung der Robustheit werden sowohl **ingenieurmäßige (deterministische) Maße**:

- es werden Grenzwerte überschritten
- es treten unerwünschte plötzliche Änderungen in den Antwortgrößen auf
- es werden Systeminstabilitäten angesprochen (Beulen, Resonanzerscheinungen,...)

als auch **statistische Maße**

- Mittelwerte verschieben sich zu sehr
- Variationskoeffizienten werden zu groß

herangezogen.

Neben der Bewertung einzelner Responsegrößen, können die Verknüpfung von Ursache und Wirkung, dass heißt welche streuenden Inputparameter für welche streuenden Responsegrößen verantwortlich sind, aus den Korrelationsstrukturen bestimmt werden.

Zusätzlich zu den klassischen Sensitivitätsuntersuchungen, die mittels einer Berechnung extremer Parameter-Kombinationen, analytischer Ableitungen, Design of Experiments (DOE) oder Response Surface Approximations die Änderung von Systemantworten bezüglich der Änderung von Input-Variablen anzeigt, legt die Robustheitsbewertung sozusagen einen Wahrscheinlichkeitsfilter über den Sensitivitätsraum, der die Auftretenswahrscheinlichkeit der Parameterkombinationen berücksichtigt. Unmögliche Ereignisse oder extrem seltene Ereignisse mit einer sehr kleinen Auftretenswahrscheinlichkeit werden somit nicht betrachtet. Es sei darauf hingewiesen, dass dieser Wahrscheinlichkeitsfilter von einem konkreten Design (für welches die Robustheit bewertet werden soll) ausgehend die Sensitivitäten von häufigen Ereignissen höher wichtet als von seltenen Ereignissen. Damit werden mögliche Ereignisse in Abhängigkeit der Wahrscheinlichkeit des Auftretens des Ereignisses bewertet. Unmögliche Ereignisse oder extrem seltene Ereignisse mit einer sehr kleinen Auftretenswahrscheinlichkeit werden nicht betrachtet. Zur Sicherung der Aussagekraft der Robustheitsbewertung für seltene Ereignisse sind dann gegebenenfalls sehr viele Stichproben notwendig bzw. es sollten Verfahren der Safety and Reliability Analysis angewendet werden.

Aus Sicht der zu lösenden Ingenieuraufgabe können Robustheitsprobleme verschiedene Ursachen haben. So können Robustheitsprobleme aus Unzulänglichkeiten des **Simulationsprozesses**, z.B. aus den verwendeten numerischen Methoden, den Modellen oder den Werkzeugen resultieren:

- Hardware (z.B. unterschiedliche Speicherverwaltung)
- Software (z.B. kleine Variation von Approximationsfehlern [Zeitschrittintegration, Zahlenformatbeschränkungen])
- Berechnungsverfahren (z.B. Ergebnis der Optimierung hängt von kleinen Änderungen von Verfahrensparametern ab)
- Modellierung/Diskretisierung (Netzeinflüsse, Modellinstabilitäten)

Für **Robustheitsbewertungen gegenüber dem Simulationsprozess** werden i.d.R. zufällige Streuungen (weißes Rauschen) auf beliebige Parameter (Modellparameter, numerische Parameter, physikalische Parameter) aufgebracht und die Stabilität der Lösung bewertet. Treten hierbei nennenswerte Unterschiede auf, müssen die Ursachen identifiziert werden. Hierbei ist es manchmal nicht trivial zwischen Unzulänglichkeiten des Simulationsprozesses, welche möglichst abgestellt werden sollten, und durch das verursachte Rauschen angeregte physikalische Instabilitäten zu unterscheiden. Können physikalische Ursache dieser Instabilitäten (z.B. geometrische Imperfektionen) identifiziert werden, sollten in der Folge Robustheitsbewertungen des Designs, mit der Definition physikalisch relevanter Streuungen der physikalischen Parameter durchgeführt werden.

Maßgebend für die Bewertung von Funktionsfähigkeit, Funktionssicherheit und Zuverlässigkeit sind **Robustheitsbewertungen gegenüber dem Designentwurf**. Hierbei wird die Robustheit gegenüber Designparametern (Material, Geometrie, Lasten, Randbedingungen) und deren in Natura vorhandenen Streuungen bewertet. Zum Nachweis der Robustheit des Designs sollten dann alle wesentlichen Unsicherheiten physikalischer Parameter mit physikalisch sinnvollen Streuungen beschrieben werden und der Einfluss auf die Streuungen aller wesentlichen Systemantworten bewertet werden.

Vor allem für stark nichtlineare Simulationsprozesse ist ein iteratives Vorgehen der Robustheitsbewertung des Simulationsprozesses sowie des Designentwurfs zu empfehlen:

- Robustheitsbewertung gegenüber dem Simulationsprozess
 - o Beseitigung von Unzulänglichkeiten des Simulationsprozess
 - o Ableiten sensibler physikalischer Parameter
- Robustheitsbewertung gegenüber dem Designentwurf
 - o Ermittlung der wesentlichen Unsicherheiten
 - o Definition der Streuungen der wichtigsten physikalischen Parameter
 - o Ermittlung der wichtigsten Korrelationen zu den Systemantworten

2.1 Erzeugung des Sampleset

Grundlage einer Robustheitsbewertung ist ein statistisch aussagefähiger Satz möglicher Realisierungen (Stichproben/Sampleset).

2.1.1 Stochastische Samplingverfahren

Basisverfahren der stochastischen Analyse zur Erzeugung des Sampleset beruhen auf Varianten der Monte-Carlo-Simulation. Besonders einfach zu realisieren ist das sogenannte „Plain-Monte-Carlo-Verfahren“, bei dem die Zufallszahlen nach einer gegebenen Verteilungsfunktion weitgehend unsystematisch mittels Zufallszahlengenerator erzeugt werden. Dieses Verfahren liefert allerdings bei geringen Stichproben relativ hohe statistische Unsicherheiten und benötigt in großen Parameterräumen extrem viele Stichproben. Speziell für die Robustheitsbewertung bietet sich die Variante des sogenannten Latin-Hypercube-Sampling an. Dieses etwas aufwendigere Verfahren erzeugt die Stichproben systematisch so, dass die Variationsbreiten möglichst optimal eingehalten werden und gleichzeitig unerwünschte Korrelationen zwischen Eingangsgrößen eliminiert werden können. Dadurch wird eine gute Korrelation der Inputvariablen bei wenigen Stützstellen gesichert. Der Vorteil ist eine geringere statistische Streuung der erhaltenen Ergebnisse. Selbstverständlich ist bei numerisch aufwendigen Problemstellungen darauf zu achten, dass die Rechenzeiten in realisierbaren Grenzen bleiben. So können durch Anwendung von Latin-Hypercube-Sampling im Vergleich zu Plain-Monte-Carlo teure Solverruns eingespart werden.

2.1.2 Empfohlene Stichprobenanzahl

Für eine statistische Bewertung der Einzelgrößen (Mittelwert, Histogramm, Variationskoeffizient) wird für Plane Monte Carlo-Verfahren eine Stichprobenanzahl von der Größe (Anzahl der zufälligen Responsegrößen)² als sinnvoll angesehen. Latin Hypercube Verfahren kann die notwendige Stichprobenanzahl bis zu $2 \cdot (\text{Anzahl der zufälligen Responsegrößen})$ reduzieren. Unabhängig von der Anzahl der Responsegrößen wird eine Mindestanzahl von 10 empfohlen.

Für eine statistische Absicherung der linearen Korrelationsstruktur ist im ungünstigsten Fall eine Stichprobe pro Matrixelement der Dreiecksmatrix notwendig. Bei gutartigen (insbesondere bei nahezu linearen) Problemen kann die Korrelationsstruktur unter Verwendung von Latin Hypercube Verfahren gegenüber „normalen“, nicht seltenen Ereignissen mit einer Stichprobenanzahl von **$2 \cdot (\text{Inputvariablen} + \text{Antwortgrößen})$** ermittelt werden.

Für eine Reduktion des notwendigen CPU-Aufwandes bei der Durchrechnung der Stichproben werden gelegentlich Robustheitsbewertungen unter Verwendung von Response Surface Approximationen vorgeschlagen. Dann werden die Stichproben nicht mehr Originalraum, sondern wesentlich schneller im Approximationsraum (RS-Approximation) berechnet. Die Verwendung von Response Surface Approximationen für Robustheitsuntersuchungen ist bezüglich der Eignung/Qualität der Response Surfaces für eine geeignete Abbildung von Robustheitsproblemen als sehr problematisch einzuschätzen. Es kann davon ausgegangen werden, dass gerade nichtlineare Effekte, welche zu Robustheitsproblemen führen, mit globalen Response Surface Approximationen nicht abgebildet werden. Deshalb wird die Verwendung von Response Surface Approximationen für nichtlineare Problemstellungen nicht empfohlen.

2.1.3 Beschreibung der Streuungen der Inputvariablen

Neben einem geeigneten Samplingverfahren müssen die Charakteristika wichtiger streuenden Parameter mittels Verteilungsfunktionen in ausreichender Qualität beschrieben werden. Typische Verteilungsfunktionen sind:

- Normalverteilung
- abgeschnittene Normalverteilung
- Lognormalverteilung
- Weibullverteilung
- Gleichverteilung
- diskrete Verteilung

Die Definition realistischer Verteilungsfunktionen aller wichtiger Parameter ist eine natürliche Voraussetzung der Vertrauenswürdigkeit der Ergebnisse von Robustheitsbewertungen. Für praktische Anwendungen stellt die Selektion der wichtigen Parameter und die Definition der Verteilungsfunktionen ein ernst zu nehmendes Hindernis dar. Die Selektion der wichtigen Parameter ist ein Hauptanliegen von Robustheitsbewertungen. Hier ist zu empfehlen, nicht frühzeitig den Variablen- und Responseraum einzuschränken, sondern möglichst vorhandene CPU-Reserven auszureizen und eher ein paar Variablen, Lastfälle oder Responsegrößen zuviel als zuwenig in die Robustheitsbewertungen einzubeziehen.

Zur Approximation von Verteilungsfunktionen reicht es oft schon, vorhandenes Wissen über mögliche Streuungen in geeignete Verteilungsfunktionen „zu übersetzen“. Sind Mittelwerte und mögliche maximale erwartete Streuungen bekannt, können z.B. abgeschnittene Normalverteilungen approximiert werden. Dann werden die maximalen erwarteten Streuungen einer Auftretenswahrscheinlichkeit (z.B. Sigma-Werte) zugeordnet.

Dabei wird in der Normalverteilung angenommen, dass die:

- 1-Sigma-Werte von 68.3 % aller Stichproben
- 2-Sigma-Werte von 95.4 % aller Stichproben (entspricht ungefähr dem 5 % Fraktilwert)
- 3-Sigma-Werte von 99.73 % aller Stichproben nicht überschritten werden.




Bild 1.1 Normalverteilung mit Sigma-Werten

Dann können die Variationskoeffizienten aus der Division von Standardabweichung durch Mittelwert approximiert werden. Z.B. 20 % Streuung bei einer Wahrscheinlichkeit von 2-Sigma ergibt eine Variationskoeffizient von $0.2/2 = 0.10$. Zusätzlich werden i.d.R. die Gaußverteilungen bei den Sigma-Werten der maximalen erwarteten Streuungen abgeschnitten. Dadurch ergeben die resultierenden Histogramme der Inputvariablen etwas kleinere Variationskoeffizienten.

Natürlich sollten derart approximierte Verteilungsfunktionen für die wichtigsten streuenden Variablen in der Folge verifiziert werden.

2.2 Statistische Bewertung

Die Stichproben werden mittels statistischer Verfahren auf Korrelations- und Variationseigenschaften sowie auf weitere Auffälligkeiten bezüglich der Robustheit, der Sensivität und Stabilität der Systemantwort gegenüber den Streuungen von Inputparametern untersucht. In der Folge werden statistische Größen an einer Robustheitsbewertung eines Workbookexamples von OptiSLang /1/ veranschaulicht.

2.2.1 Statistische Maße einzelner Input- und Responsegrößen

Es werden Mittelwerte, Histogramm und Variationskoeffizient der Input- und Responsegrößen berechnet. Die Bewertung der Inputgrößen dient zur statistischen Absicherung der gezogenen Stichproben. Die Verteilungen sollten mit den Sollverteilungen verglichen werden. Die Bewertung von Mittelwert und Variationskoeffizient der Responsegrößen erlaubt eine Beurteilung der Sensitivität der Systemreaktion. Dabei zeigen die **Variationskoeffizienten** das Maß der Streuung an. Auffällig sind Variationskoeffizienten von Ausgangsgrößen, die wesentlich höher liegen als die der Eingangsgrößen. Dann kann davon ausgegangen werden, dass das System die Streuungen von Inputvariablen verstärkt. Für viele Ingenieuraufgabenstellungen werden eher dissipative Systeme angestrebt, in denen die Variationskoeffizienten der Responsegrößen wesentlich kleiner als die Variationskoeffizienten der Inputgrößen sind. Die Histogramme der einzelnen Responsegrößen sollten bezüglich Clusterbildungen oder Verzweigungen, die auf Systeminstabilitäten hindeuten, untersucht werden.




Bild 2.2.1.1 Histogramm, Mittelwert und Variationskoeffizient
links: Inputgröße 3 (X3)
rechts: Responsegröße 4 (rot_3)

In Bild 2.2.1.1 ist auffällig, daß der Variationskoeffizient der Responsegröße (0.16) wesentlich größer ist als der Variationskoeffizient der Inputgröße (0.03). Beide Größen sind mit hoher Korrelation (Korrelationskoeffizient 0.88 in aus Bild 2.2.2.2) nahezu linear verknüpft. Die Streuung von Responsegröße 4 wird fast ausschließlich von Streuungen der Inputgröße 3 dominiert und das System verstärkt dabei die Streuung.

2.2.2 Korrelationsstrukturen

Neben der Bewertung einzelner streuender Responsegrößen können aus den Korrelationsstrukturen die wichtigen Verknüpfungen von Eingangs- und Responsegrößen ermittelt werden.

Korrelationsstruktur von Parameterpaaren

Zweckmäßig ist es, lineare Korrelationskoeffizienten zwischen den Input- und Responsevariablen in einer Matrix der linearen Korrelation darzustellen. Daraus kann auf einen möglichen linearen Zusammenhang zwischen den Variablen geschlossen werden. Dabei zeigen die **Korrelationskoeffizienten** das zwischen +1 bis -1 normierte Maß der Verknüpfung bzw. Abhängigkeit von zwei Variablen an.

Click on one element to see more




Bild 2.2.2.1 Lineare Korrelationsstruktur (graue Linien trennen Input-/Responsevariablen)

Parameterkombinationen mit Korrelationskoeffizienten ≥ 0.70 werden i.d.R. als auffällig bezeichnet. Es wird empfohlen, auch Parameterkombinationen bis ≥ 0.50 auf Auffälligkeiten zu untersuchen. Häufig ist zu beobachten, dass nur eine kleine Anzahl von Inputvariablen eine nennenswerte (≥ 0.50) Korrelation zu den Antwortgrößen besitzen. Diese Inputvariablen haben i.d.R. zu mehreren Responsevariablen auffällige Korrelationen und sind als Bänder in der Korrelationsmatrix wiederzufinden. Stabilisieren sich die auffälligen Inputvariablen bei mehreren Robustheitsbewertungen in verschiedenen Designphasen, können die Parameterräume reduziert werden.

Im Bild 2.2.2.1 ist die Matrix der linearen Korrelation einer Robustheitsbewertung von 9 streuenden Inputvariablen und 6 Responsegrößen abgebildet. Links unten ist deutlich zu erkennen, dass $2 \cdot (9+5) = 30$ Latin Hypercube Stichproben für die statistische Bewertung ausreichend sind und keine unerwünschte Korrelation der Eingangsgrößen mehr zeigen. Rechts unten ist deutlich zu erkennen, dass nur Inputvariablen 3 und 4 nennenswerte Korrelation zu Responsegrößen zeigen.

Jedem Matrixfeld ist ein paarweiser Anthill-Plots zugeordnet (Bild 2.2.2.2). Dabei werden im zweidimensionalen Parameterraum alle Realisierungen eines Samplesets dargestellt, welche in unkorrelierten Fällen Ameisenhaufen (Anthill) ähneln. Dies ermöglicht die visuelle Beurteilung der Korrelation und das Erkennen möglicher Häufungen (Cluster). Ebenso können nichtlineare Zusammenhänge, z.B. Verzweigungspunkte identifiziert werden.




Bild 2.2.2.2 Anthill-Plots

links: Inputvariable 4 mit Responsevariable 1

rechts: Inputvariable 3 mit Responsevariable 4

In Bild 2.2.2.2 sind die Anthill-Plots der Parameterkombinationen mit den größten Korrelationskoeffizienten der Korrelationsmatrix (Bild 2.2.2.1) dargestellt.

Korrelationsstruktur von Parametergruppen

Während lineare Korrelationsstrukturen den expliziten Zusammenhang zwischen der Variation von zwei Variablen, z.B. einer Inputgröße zu einer Responsegröße bewerten, werden mit sogenannter **Principal Component Analysis (PCA)** der linearen Korrelationsmatrix höherdimensionale Korrelationen, die Auffälligkeiten von Korrelationen einer Gruppe von Inputvariablen zu einer Gruppe von Responsevariablen untersucht. Eine Eigenwertzerlegung der linearen Korrelationsstruktur ergibt dabei die dominierenden Korrelationsmodi. Vergleichbar mit einer modalen Eigenwertanalyse, wo die ersten Eigenwerte das globale dynamische Strukturverhalten dominieren, dominieren die ersten Korrelationsmoden das globale hochdimensionale Korrelationsverhalten. Deshalb werden i.d.R. nur die ersten 2-10 Principal Components auf Auffälligkeiten untersucht. Zweckmäßigerweise werden die Eigenwerte der linearen Korrelationsstruktur (sogenannte Principal Components) bestimmt, normiert und sortiert und in Matrixform als dyadisches Produkt dargestellt. Die Matrixdarstellungen der Principal Components zeigen dann die Beiträge von **Variablengruppen** zur Streuung des gesamten Input/Output- Datensatzes und deren dabei auftretende lineare Abhängigkeiten an.




Bild 2.2.2.2 Matrixdarstellung der zweiten Principal Component

In Bild 2.2.2.2 ist zu sehen, dass der zweite Korrelationsmode die Inputvariablen 1,2,4,5 und 8 mit den Responsegrößen 5 und 6 verknüpft.

3 Zusammenfassung

Robustheitsbewertungen sind ein wichtiger Bestandteil des virtual prototyping bei der Bewertung von Funktionsfähigkeit, Funktionssicherheit und Zuverlässigkeit von Strukturen. Dabei werden sowohl die Robustheit gegenüber dem Simulationsprozess als auch die Robustheit gegenüber unvermeidbaren Streuungen von Designparametern untersucht.

Praktische Anwendungen zeigen, dass mittels Latin Hypercube Samplingverfahren auch größere Parameterräume (> 100 Input-/Responsevariablen) mit moderaten Rechenaufwand bewertet werden können. Mit einer geeigneten statistischen Bewertung sowie mittels Korrelationsanalyse und Principal Component Analysis können Robustheitsprobleme, Instabilitäten sowie dafür verantwortliche streuende Inputparameter und deren Verknüpfung zu den Responsegrößen bestimmt werden.

Weiterhin können Robustheitsuntersuchungen zur Reduktion der Problemdimension im wahrscheinlichkeitsgewichteten Design-Raumes verwendet werden, so dass die Anwendung der stochastischen Systemanalyse mit nur wenigen wichtigen streuenden Parametern für die Bewertung der Sicherheit und Zuverlässigkeit ermöglicht wird. Nachdem die wichtigsten streuenden Parameter mittels Robustheitsbewertungen herausgefiltert worden sind, können Berechnungen von Auftretenswahrscheinlichkeiten (Versagen, Überschreitungen) [Safety and Reliability Analysis] durchgeführt werden.

Alle beschriebenen stochastischen und statistischen Algorithmen sind in der Software SLang [2] implementiert. Die Robustheitsbewertungen wurden mit OptiSLang [1] durchgeführt.

4 References

- [1] OptiSLang - the Optimizing Structural Language Version 1.3, DYNARDO, Weimar, 2003, www.dynardo.de
- [2] Bucher C. et al.: SLang - the Structural Language Version 5.0, Institute of Structural Mechanics - Bauhaus-University Weimar, 2002
- [3] Bucher, C.: "Some Recent Software Developments for Stochastic Structural Analysis", in N. Shiraisi et al. (ed.): Structural and Reliability, Balkema/Rotterdam/Brookfield, Vol. 1, pp 541-547, 1998
- [4] Bucher, C.: "Application of probability-based concepts in computational mechanics", in Wunderlich (ed.) Proceedings, ECCM99, Munich, 1999
- [5] 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