

# **Bewertung von Berechnungsergebnissen mittels Stochastischer Simulationsverfahren**

Assessment of Analysis Results using Stochastic Simulation Methods

Dipl.-Wirtsch. Ing. **Ralf Reuter**, Alzenau; Dipl.-Ing.(FH) M. Sc. **Rainer Hoffmann**, Alzenau

## **Zusammenfassung**

Um echten Nutzen aus den Ergebnissen numerischer Simulationen ziehen zu können, müssen diese so zuverlässig sein, daß sie als Entscheidungsgrundlage bei wichtigen Stufen im Entwicklungsprozess von Kraftfahrzeugen dienen können. Greift man jedoch auf Ergebnisse deterministischer Simulationen zurück, birgt dies erhebliche Risiken, wenn man bedenkt, daß die simulierten Vorgänge (z.B. Crashversuche) hochgradig komplex, nicht-linear und vor allem nicht-reproduzierbar sind. Streuungen in praktisch allen Systemeigenschaften (Materialeigenschaften, Geometrien usw.) sowie in Rand- und Anfangsbedingungen verursachen natürlich auch Streuungen im Verhalten des Systems (z.B. Deformationsverhalten beim Crash). Stochastische Simulationen sind ein Ansatz bei dem Streuungen aus der Realität konsequent in die Simulationsmodelle übertragen werden. So wird es möglich, auch die Streuung der Simulationsergebnisse zu ermitteln und Aussagen über die Zuverlässigkeit und damit letztendlich über die Qualität des simulierten Systems zu treffen.

Das vorliegende Paper gibt einen konzeptionellen Überblick über die Grundlagen der Methode. Es wird aufgezeigt, welchen Zusatznutzen die Anwendung in der Praxis liefert. Die praktische Anwendung und der Nutzen der vorgestellten Methode wird anhand von zwei Beispielen demonstriert.

## **Summary**

In order to yield significant added value, numerical simulations need to reach a level of reliability that enables decisions, which are only based on simulation results. If one uses results from deterministic simulations, such decisions involve considerable risks. The

simulated systems and events (e.g. crash tests) are highly non-linear and non-reproducible. Scatter in all system properties and boundary conditions also cause scatter in the performance of the system. Stochastic simulations are an approach to include this natural scatter into simulation models. This allows evaluating the performance scatter and thus an assessment of reliability and quality of the simulated system.

This paper gives an overview of the basics of the stochastic simulation method. It shows the added value generated by the application of the method. Two examples illustrate the application in practise.

## **1 Einleitung**

Obwohl numerische Berechnungsverfahren zweifellos einen wichtigen Beitrag zur Verkürzung der Entwicklungszeiträume geleistet haben, sind es immer noch physikalische Versuche, die in den meisten Fällen als Grundlage für Entscheidungen im Entwicklungsprozess dienen. Die häufig vorgetragene Vision von der virtuellen Entwicklung, die ganz im Rechner stattfindet und auf Versuche verzichten kann (vgl. z.B. /1/, S.177), ist offenbar noch ein gutes Stück von der Realisierung entfernt. Die erhoffte dramatische Reduzierung der physikalischen Versuche ist bislang ausgeblieben.

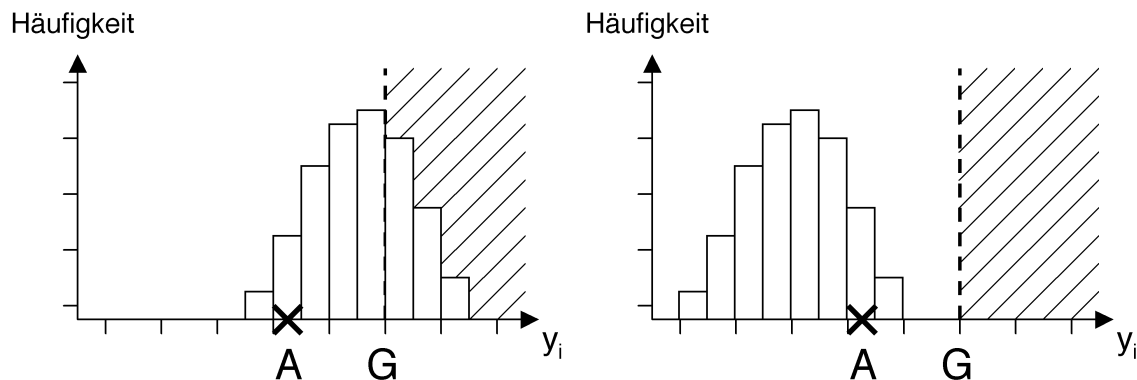
Die Gründe dafür sind vielfältig. Einer davon ist sicher der, daß die Entscheidungsträger den Berechnungsergebnissen nicht in dem Maße vertrauen wie sie Versuchsergebnissen trauen. Wer kann ihnen das auch verdenken? Vergleicht man die Ergebnisse aus Simulation und Versuch, wird man in jedem Fall mehr oder weniger große Abweichungen feststellen. Nie liefern beide Methoden exakt gleiche Ergebnisse. Da aber die Entscheidungen nicht für die virtuelle, sondern für die physikalische Welt getroffen werden müssen, liegt es nahe, den physikalischen Ergebnissen mehr Vertrauen zu schenken. Diese, auf den ersten Blick einleuchtende Logik enthält jedoch einen kleinen Denkfehler: Würde man den physikalischen Versuch mehrfach unter gleichen Bedingungen wiederholen, erhielte man ebenfalls nicht immer das gleiche Ergebnis. Die Ursache hierfür liegt in der nicht vermeidbaren (bestenfalls reduzierbaren) Streuung der Eigenschaften des untersuchten Systems und der Randbedingungen des Versuchs. Insofern kann und sollte man weder beim Vergleich Versuch/Versuch noch beim Vergleich Simulation/Versuch exakte Übereinstimmung einzelner Durchführungen erwarten. Was Übereinstimmen muß, ist vielmehr das Gesamtbild,

das sich erst aus mehreren Durchführungen ergibt, also die statistische Beschreibung der Ergebnisse (z.B. Mittelwerte, Streuungsmaße, Verteilungen).

Was bedeutet das für die Simulation? Wenn die Berechner dazu übergehen würden, statt eines einzelnen (deterministischen) Ergebnisses, eine statistische Ergebnisbeschreibung zu erzeugen, würden Berechnungsergebnisse sehr viel eher das Vertrauen der Entscheider gewinnen. Denn dann würde man sehr oft (vorausgesetzt natürlich die verwendeten Modelle sind gut) eine Übereinstimmung von Simulation und Versuch finden. Hinzu kommt, dass es sehr viel weniger aufwendig ist, eine solche statistische Beschreibung mittels Simulationen zu erzeugen, als mittels Versuchen. Darin liegt auch direkt ein enormer Vorteil den Simulation gegenüber dem Versuch haben kann: Durch die Möglichkeit eine genaue statistische Beschreibung geben zu können, ergibt sich die Möglichkeit Sicherheitsfaktoren erheblich zu verringern. Denn Sicherheitsfaktoren oder -abstände sind nichts anderes als ein Ausdruck der Unsicherheit bezüglich der Ergebnisse. Das gilt sowohl für Simulation als auch für den Versuch. Weil ein einzelnes Ergebnis wenig aussagekräftig ist und man sich sehr wohl der Tatsache bewußt ist, daß es Streuungen gibt, fordert man ein Übertreffen des eigentlich gewünschten Ergebnisses um einen bestimmten, oft sehr hohen, Betrag. Das ist natürlich oft aufwendig, schwer zu erreichen und teuer. Kennt man dagegen die statistische Beschreibung des Ergebnisses und weiß damit wie stark die Streuung wirklich ist, dann kann man sich oft wesentlich näher an das eigentlich gewünschte Ergebnis heranwagen. Die statistische Beschreibung ermöglicht die Berechnung von Versagenswahrscheinlichkeiten und gibt so wesentlich bessere Möglichkeiten zur Beurteilung als der Abstand eines einzelnen Ergebnisses vom Grenzwert.

Abbildung 1 verdeutlicht den Unterschied zwischen deterministischer und stochastischer Simulation hinsichtlich der Möglichkeiten zur Bewertung der Ergebnisse. Es wird ein beliebiger Leistungs-Kennwert  $y_i$  eines Systems betrachtet und zwei verschiedene Systemvarianten verglichen. Der Grenzwert  $G$  stellt den maximal zulässigen Wert dar, d.h. das System versagt wenn  $y_i > G$  (schraffierter Bereich). Ein einzelner Versuch oder eine (deterministische) Berechnung hat den Wert  $A$  ergeben. Der Sicherheitsabstand  $s$  des Wertes  $A$  beträgt  $s=G-A$ . Der Sicherheitsabstand der sich aus der Betrachtung der Einzelergebnisse ergibt, ist für beide Varianten identisch. Betrachtet man jedoch die statistische Beschreibung von  $y_i$  in Form eines Histogramms, sieht man einen deutlichen Unterschied. Bei der linken Variante überschreitet eine große Zahl von Fällen den Grenzwert, daher ist die Versagenswahrscheinlichkeit sehr hoch. Rechts dagegen wird der

Grenzwert in keinem der untersuchten Fälle überschritten, welches eine geringe Versagenswahrscheinlichkeit ergibt (jedoch nicht gleich 0, da hier ja nur eine Stichprobe betrachtet wird!). Das linke System würde man zweifellos nicht akzeptieren, während sich beim rechten u.U. sogar noch Einsparpotentiale ergeben würden, da es noch einen gewissen Spielraum bis zum Grenzwert aufweist.



**Abbildung 1: Versagenswahrscheinlichkeit und Sicherheitsabstand**

Das obige Beispiel zeigt, daß der Nutzen numerischer Simulationen sehr groß sein kann, wenn sie wirklich relevante Informationen liefern. Wenn sie dagegen deterministisch Einzelfälle analysieren, muß die Relevanz zumindest kritisch in Frage gestellt werden. Man muß sich darüber im klaren sein, daß es sich bei dem simulierten Fall, auch wenn es sich um den sogenannten Nominalfall handelt, keineswegs um einen besonders wichtigen Fall handelt, sondern daß dieser eben nur einer aus einer unendlich großen Zahl möglicher Fälle ist und in der Realität praktisch nie vorkommt. Insofern kann es sehr riskant sein sich auf die Ergebnisse dieses Nominalfalls zu verlassen. Besser wäre es da schon, wenn man den ungünstigsten Fall betrachten könnte (wobei dessen Relevanz auch nicht sehr groß ist, da er in der Praxis ebenfalls eine minimale Eintrittswahrscheinlichkeit hat). Dies scheidet aber in der Regel daran, daß man bei einem einigermaßen komplexen System diesen Fall gar nicht a priori bestimmen kann. Insofern liefert erst die statistische Beschreibung ein umfassendes Bild, welches eine Wertung ermöglicht. Die Statistik gibt z.B. Auskunft über das wahrscheinlichste Ergebnis, die möglichen Abweichungen davon (Streuungsmaße, Konfidenzintervalle) und Wahrscheinlichkeiten für bestimmte Ereignisse. Anhand dieser Informationen, welche durch Stochastische Simulation wirtschaftlich erzeugt werden, können Entscheider fundierte Entscheidungen treffen.

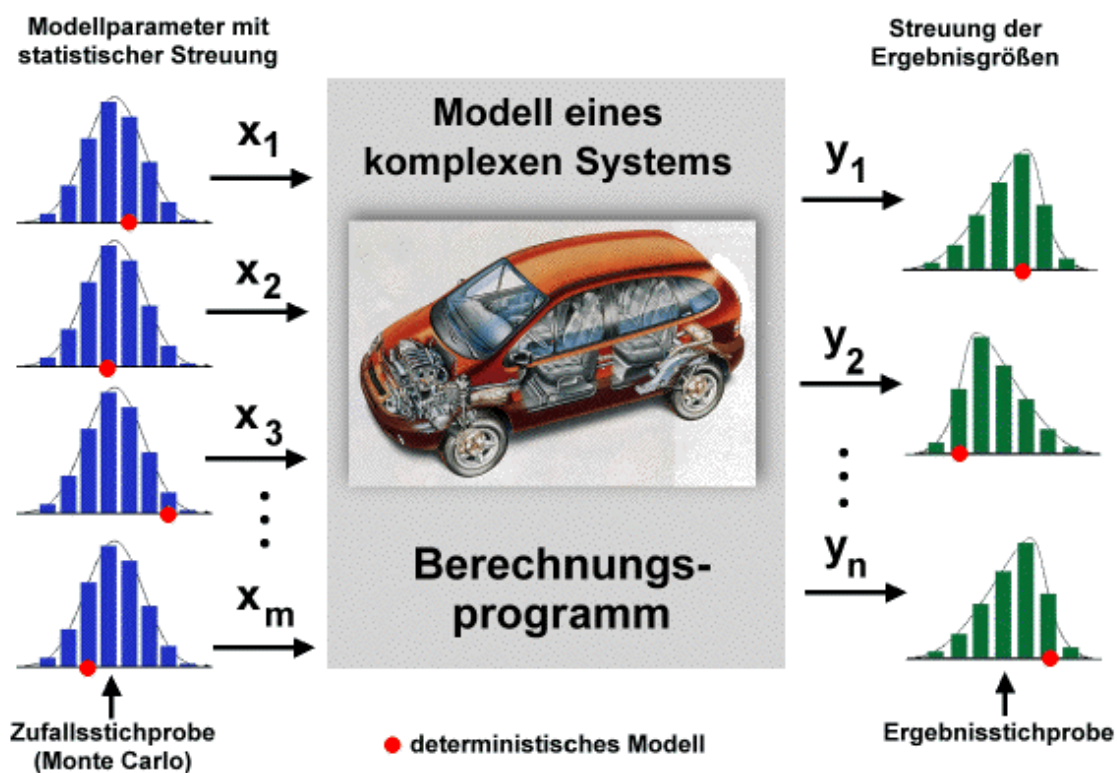
## **2 Stochastische Simulationen mit der Monte-Carlo Methode**

Dieser Abschnitt beschreibt Grundlagen der Stochastischen Simulation und zeigt die wichtigsten Anwendungen der Methode auf.

### **2.1 Grundlagen der Stochastischen Simulation**

Zur Erzeugung der oben geforderten statistischen Beschreibung des Verhaltens eines Systems bieten sich Stochastische Simulationen mit der Monte-Carlo Methode an (vgl. hierzu ausführlich /2/). Das Prinzip dieser Methode ist recht einfach: Basierend auf einem nominalen Ausgangsmodell erzeugt man Kopien des Modells (Clones) wobei bestimmte Parameter des Modells durch Zufallszahlen ersetzt werden, die jedoch vorgegebenen statistischen Verteilungen gehorchen. So entsteht eine Zufallsstichprobe des Modells. Jedes Model unterscheidet sich minimal von den übrigen Modellen, genau wie sich jedes reale System (z.B. ein Bauteil), selbst wenn es auf den gleichen Maschinen und mit dem gleichen Verfahren hergestellt wurde, minimal von allen anderen unterscheidet. Typischerweise liegen die Stichprobenumfänge zwischen 50 und 100. Besonders ist auf die Tatsache hinzuweisen, daß der Stichprobenumfang bei dieser Methode nicht von der Anzahl der Variablen abhängt, sondern nur von der Art und Genauigkeit der gewünschten statistischen Ergebnisbeschreibung. So können Maße der zentralen Lage, wie Mittelwert und Median, schon mit geringen Stichprobenumfängen genau bestimmt werden. Zur Vorhersage von Wahrscheinlichkeiten seltener Ereignisse sind jedoch größere Umfänge, bzw. spezielle Monte-Carlo Algorithmen notwendig.

Abbildung 2 faßt das Prinzip der Stochastischen Simulation schematisch zusammen.




**Abbildung 2: Schematische Darstellung einer Stochastischen Simulation**

Alle so erzeugten Modelle der Stichprobe werden anschließend simuliert (linke Hälfte der Abbildung 2). Obwohl dies je nach Art und Größe des Modells und gewähltem Berechnungsverfahren ein erheblicher Rechenaufwand sein kann (bei Crashesimulationen kann der Umfang durchaus 10000 CPU-Stunden übersteigen), kann man, bedingt durch die Tatsache, daß alle Modelle unabhängig voneinander sind, einen Parallelisierungsgrad von 100% erzielen. Im Idealfall kann die gesamte Stichprobe gleichzeitig berechnet werden, wenn die Anzahl der verfügbaren Rechner (CPUs) größer oder gleich dem Stichprobenumfang ist. Dies ist in der Industrie heute keine Seltenheit mehr, so daß der Anwendung der Methode heute oft kein Mangel an Rechenkapazität mehr entgegensteht.

Als Ergebnis der Berechnung aller Modelle erhält man die Rohdaten, die anschließend statistisch auszuwerten sind (rechte Hälfte der Abbildung 2). Die Auswertung umfaßt z.B. die Berechnung wichtiger Maße der Lage (z.B. Mittelwert) und Streuung (z.B. Standardabweichung), die Untersuchung von Zusammenhängen zwischen Variablen mittels Korrelations- oder Regressionsanalysen, sowie die graphische Aufbereitung der Daten in Form von Histogrammen oder Streudiagrammen. Von besonders großer Bedeutung in der Praxis ist die Untersuchung der Zusammenhänge von Variablen und zwar sowohl die der

Zusammenhänge zwischen den variierten Modellparametern und der Ergebnissen als auch die der Zusammenhänge zwischen den verschiedenen Ergebnissen. Die Kenntnis dieser Zusammenhänge ist von großer Bedeutung, wenn es darum geht ein System zu verbessern. Besonders wichtig ist dabei die Tatsache, daß bei der stochastischen Simulation die Einflüsse nicht getrennt ermittelt werden, sondern bei gleichzeitiger Variation aller Parameter des Modells. Nur so kann man die Parameter identifizieren, die auch in der Realität das Systemverhalten stark beeinflussen. Parameter deren Einfluß man dagegen nur nachweisen kann indem man alle anderen festhält (was man in der Realität ja gar nicht kann), sind nicht geeignet das Verhalten eines System signifikant zu beeinflussen.

Abbildung 3 verdeutlicht diesen Unterschied: Im oberen Streudiagramm ist der Zusammenhang von  $x_i$  und  $y_i$  dargestellt wobei alle anderen Variablen  $x$  festgehalten wurden. In den beiden unteren Diagrammen wurden die Zusammenhänge auf Basis einer stochastischen Simulation ermittelt. Links zeigt sich trotz der Streuung aller anderen Variablen noch ein klarer Zusammenhang, die Variable  $x_i$  hat demzufolge einen wirklich starken Einfluß auf  $y_i$ . Rechts dagegen verschwindet der Zusammenhang durch die Streuung der übrigen Variablen völlig,  $x_i$  ist also nicht geeignet um  $y_i$  zu steuern.



**Abbildung 3: Zusammenhänge zweier Variablen**

## 2.2 Robustheitsuntersuchungen

Die Einsatzmöglichkeiten stochastischer Simulationen sind vielfältig. Eine häufige Anwendung sind Robustheitsuntersuchungen von Simulationsmodellen. Hierbei geht es in erster Linie darum, zu überprüfen, wie ein Simulationsmodell auf Streuung der System-

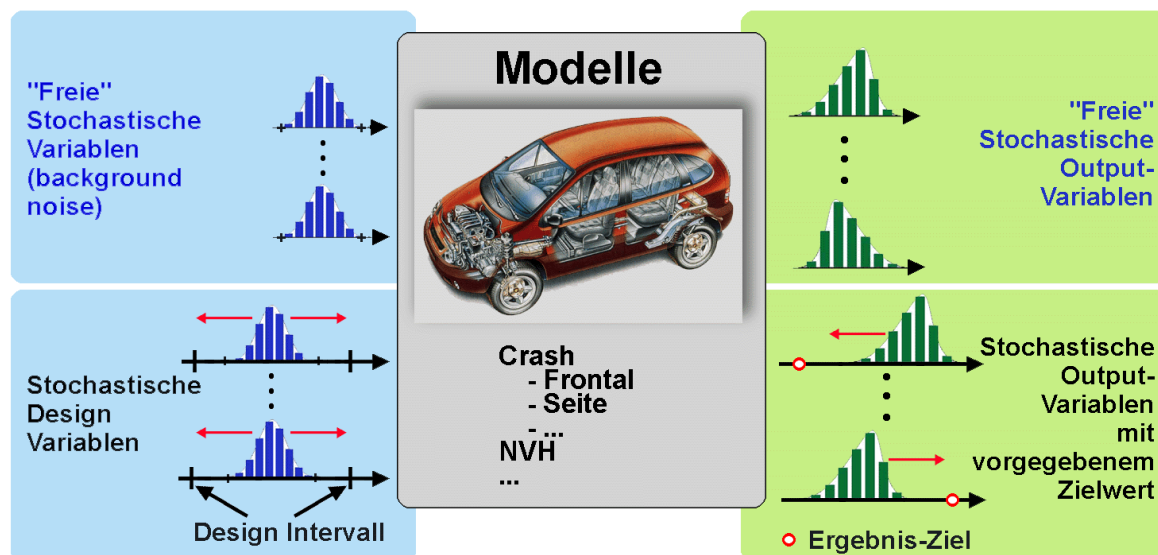
Parameter (Inputs) reagiert. Man vergleicht dabei die Streuung der System-Parameter mit der der Ergebnisse (Outputs). Normalerweise sollte sich die Streuung der Outputs in etwa in der gleichen Größenordnung wie die der Inputs bewegen. Ist sie dagegen wesentlich höher, bedeutet dies, daß eine (in der Regel unerwünschte) Streuungsverstärkung vorliegt. In vielen Fällen ist die Verstärkung allein im Simulationsmodell begründet und beruht auf numerischen Problemen im jeweiligen Berechnungsmodell und/oder -programm. Man erkennt dies daran, daß die stark streuenden Ergebnisse nicht mit physikalischen Parametern korrelieren. In diesem Fall muß das Simulationsmodell überarbeitet werden, da andernfalls die Ergebnisse rein vom Zufall abhängen und somit irrelevant werden. In Fällen in denen dagegen eine deutliche Korrelation vorliegt, deutet die große Streuung auf eine ungünstige Gestaltung des Systems hin, da es auf geringfügige Streuungen der System-Parameter mit großen Ergebnisstreuungen reagiert. Ein solches System ist in der Praxis nur schwer kontrollierbar, es kann nur gesteuert werden, indem man die Streuung der System-Parameter sehr gering hält. Das bedeutet aber nicht anderes, als die Verwendung sehr enger Toleranzen, was meist teuer und aufwendig, wenn nicht sogar unmöglich ist.

### **2.3 Verbesserung von Systemen**

Als weitere Anwendung stochastischer Simulationen bietet sich die Verbesserung von Systemen an (vgl. /2/ S. 106ff und /5/). Es wird hier bewußt auf den Begriff Optimierung verzichtet, da es weniger darum geht optimale Lösungen im mathematischen Sinne zu finden, sondern darum, für die Praxis ausreichend gute und vor allem robuste Lösungen zu entwickeln. Denn in Anbetracht der Unvermeidbarkeit von Streuungen ist Robustheit, sprich Unempfindlichkeit gegenüber diesen Streuungen, weitaus wichtiger. Optimale Lösungen funktionieren oft nur im Computer, da nur dort die Bedingungen künstlich eingefroren werden können. Eine Lösung die, ohne optimal zu sein, die Anforderungen an das jeweilige System nachweisbar auch unter realen und damit unsicheren Bedingen erfüllt, ist in den meisten Fällen zweifellos dem mathematisch-theoretischen Optimum vorzuziehen. Hinzu kommt noch, daß das Optimum, wie es von den eingesetzten Optimierungsprogrammen ermittelt wird, in den meisten Fällen nicht wirklich ein Optimum darstellt. In der Regel kann nämlich kein Beweis der Optimalität geführt werden. Oft gilt das Optimum nur wenn bestimmte Annahmen (z.B. hinsichtlich der Funktion die eine sog. Response Surface beschreibt) erfüllt sind. Ändert man diese Annahmen, ist plötzlich eine andere Lösung „optimal“.

Die Verbesserung mittels Stochastischer Simulation ist eine sehr natürliche Vorgehensweise, die sich insbesondere dadurch auszeichnet, daß sie ohne Annahmen und Bedingungen auskommt. In der Praxis ist es so, daß es für ein System eine recht kleine Anzahl sog. Designparameter gibt, also solcher Parameter, die man innerhalb eines vorgegebenen Rahmens (= Design Intervall, vgl. Abbildung 4) ändern kann, um das System zu verbessern. Daneben gibt es natürlich viele weitere Parameter (diese werden auch als freie stochastische Variablen bezeichnet, vgl. Abbildung 4), die sich im Rahmen ihrer Streuung zufällig ändern. Es gibt nun zwei verschiedene Möglichkeiten zur Verbesserung eines Systems:

Eine Möglichkeit Verbesserungen zu erzielen ist die sogenannte *direkte Methode*. Dabei man führt eine Stochastische Simulation durch, bei der man die Designparameter über den gesamten möglichen Bereich (=Design Intervall) streut, indem man diesen Variablen eine Gleichverteilung in den Grenzen des Design Intervalls zuweist. Man kann dabei von einem Scan des gesamten möglichen Designraums sprechen. Aus den Ergebnissen läßt sich unmittelbar die beste Lösung ablesen. Dieses direkte Verfahren ist relativ rechenaufwendig, da man meist große Stichproben braucht um den Designraum umfassend zu scannen. Sie bietet sich deshalb für Modelle mit relativ kurzen Rechenzeiten an. Die Methode zeigt oft sehr große (und nicht selten überraschende) Verbesserungspotentiale auf, da sie Regionen des Designraums exploriert, die mit konventionellen Methoden nicht untersucht werden.



**Abbildung 4: Konzept der Stochastischen Verbesserung**

Alternativ dazu kann auch iterativ vorgegangen werden. Man spricht dann auch von *Stepping* oder *Return Mapping* (vgl. /4/, S. 139). Bei dieser Methode nähert man sich schrittweise, beginnend an einem beliebigen Startpunkt, schrittweise einem Zielwert. Wie schon erwähnt, kommt es in der Regel nicht darauf an eine optimale Lösung zu finden, sondern eine Lösung die den tatsächlichen Anforderungen (z.B. aus dem Lastenheft) genügt. Genau diese Anforderungen gibt man als Zielwerte vor. Hier unterscheidet sich die Methode von typischen Optimierungsverfahren, wo man ohne Zielvorgabe ein mathematische Optimum zu finden versucht.


Nach der Definition von Start- und Zielpunkten erzeugt man eine kleine Stichprobe (ca. 15 Fälle) mit kleinerer Streuung um den Startpunkt herum. Innerhalb dieser Stichprobe ermittelt man die Distanz jeden Falls zu dem Zielwert im n-dimensionalen Raum und generiert dann eine neue Stichprobe um den besten Fall herum. Dies geschieht durch Verschiebung der Mittelwerte der Designparameter auf den Wert den der jeweilige Parameter im besten Fall angenommen hat. Diesen iterativen Vorgang wiederholt man so lange, bis man die Ziele erreicht hat, bzw. bis man ihnen nahe genug gekommen ist. Die Methode kommt meist mit deutlich weniger Rechnungen aus als die erstgenannte Alternative und ist deshalb eher für Modelle mit langen Rechenzeiten geeignet. Anders als die direkte Methode gibt sie jedoch nicht einen globalen Überblick über die möglichen Lösungen und weist unter Umständen eine Abhängigkeit der Ergebnisse vom Startpunkt auf. Sie ist damit eher für kleine Verbesserungsschritte geeignet. In der Praxis wird diese Methode häufig erfolgreich zur Reduzierung der Masse von Fahrzeugstrukturen angewandt. Hierbei werden die Blechdicken der Karosserieelemente variiert und meist mehrere Lastfälle aus dem Bereich Crash (Front, Seite) und dem Bereich Steifigkeit/NVH gleichzeitig betrachtet. Die multidisziplinäre Vorgehensweise wird durch das Programmpaket ST-ORM /3/ ermöglicht.

## **2.4 Validierung von Modellen**

Als dritte und wahrscheinlich wichtigste Anwendung der Stochastischen Simulation sei hier die Modellvalidierung genannt (vgl. auch /2/, S. 38-41 und /4/). Validierte Modelle sind die Grundvoraussetzung für den sinnvollen Einsatz der Computersimulation. Der heute oft praktizierte 1:1 Abgleich zwischen einem Versuch und einem Modell genügt den Anforderungen an eine Validierung jedoch nicht. Wie Eingangs schon erläutert kommt es gar nicht darauf an, daß Modell und Versuch gleiche Ergebnisse liefern wenn man jeweils nur einen Fall betrachtet. Vielmehr kommt es darauf an, die statistischen Charakteristika (z.B.

Mittelwerte, Streuungsmaße, Korrelationen) in Einklang zu bringen. Man braucht also im Idealfall sowohl eine Versuchsstichprobe als auch eine Simulationsstichprobe, um diese Charakteristika ermitteln zu können. Für die Simulation kann diese Stichprobe mittels Stochastischer Simulation generiert werden. Bei Versuchen ist dies natürlich ungleich aufwendiger, jedoch zwingend erforderlich, um die Verlässlichkeit der Aussagen der Simulation sicherzustellen.

Abbildung 5 illustriert den Unterschied zwischen 1:1 Abgleich und Stochastischer Validierung. Links ist ein Fall abgebildet, bei dem Simulation und Versuch im 1:1 Abgleich hinsichtlich der Outputs  $y_i$  und  $y_k$  sehr gut übereinstimmen. Daneben sind zwei Fälle abgebildet bei denen größere Stichproben verglichen werden. Stammt der 1:1 Abgleich aus dem mittleren Fall, ist zumindest eine notwendige Bedingung für die Validität des Modells erfüllt: der Zusammenhang der beiden hier betrachteten Variablen wird vom Modell richtig wiedergegeben. Rechts dagegen ist der Zusammenhang der Variablen im Modell ganz anders als im Versuch. Das Modell ist offensichtlich nicht gültig. Aus dem 1:1 Abgleich kann man den Unterschied jedoch überhaupt nicht erkennen.



**Abbildung 5: 1:1 Abgleich und Stochastische Validierung**

Die im Rahmen der Modellverbesserung beschriebenen Methoden (vgl. Abschnitt 2.3) können natürlich auch dazu verwendet werden, ein Simulationsmodell das zunächst weit von den Versuchsergebnissen entfernt ist dorthin zu transportieren.

Neben den drei hier beschriebenen wichtigsten Anwendungen Stochastischer Simulationen gibt es zahlreiche weitere Spezialanwendungen dieser Methode, auf die hier nicht näher eingegangen werden soll.

### 3 Anwendungsbeispiele

Im Folgenden soll anhand zweier Beispiele die praktische Anwendung der Methode gezeigt werden. Das erste Beispiel zeigt die FE-Simulation eines Kopfaufpralls nach FMVSS 201 auf

die B-Säule eines PKW mit dem Berechnungsprogramm LS-DYNA (vgl. hierzu /5/). Im zweiten Beispiel wird die Verbesserung eines Rückhaltesystems dargestellt. Hierbei kommt der kombinierte MKS/FE Solver MADYMO3D zum Einsatz (vgl. hierzu /6/).

### 3.1 Beispiel 1: Kopfaufprall-Simulation

Die US Norm FMVSS 201 (vgl. /7) schreibt Kopfaufpralltests für verschiedene Punkte des Fahrzeuginnenraums vor. Dabei wird ein kopfförmiger Prüfkörper (Free Motion Headform – FMH) mit einer definierten Geschwindigkeit auf festgelegte Prüfpunkte geschossen. Im Prüfkörper wird die Beschleunigung beim Aufprall gemessen und daraus das Head Injury Criterion (HIC) berechnet. Der HIC(d) Wert ist wie folgt definiert (vgl. /7/, S. 3):


$$HIC(d) = 0,75446 \max_{t_1, t_2} \frac{1}{t_2 - t_1} \int_{t_1}^{t_2} a dt^{2,5} (t_2 - t_1) + 166,4 \quad (1)$$

mit a = resultierende Beschleunigung der FMH  
 und  $t_2 - t_1 = 36ms$

Der HIC-Wert darf 1000 nicht überschreiten. In der Praxis ist es oft schwer diesen Grenzwert einzuhalten, da Fahrzeugstruktur, Befestigungspunkte der Innenraumverkleidung, sowie Anbauteile oft nur einen geringen Deformationsweg zulassen was naturgemäß zu hohen Beschleunigungen führt. Simulationen werden eingesetzt, um ein günstiges Deformationsverhalten herbeizuführen.


Im vorliegenden Fall wurde der Aufprall an einen Prüfpunkt der B-Säule mit dem Solver LS-DYNA simuliert. Abbildung 6 zeigt einen Ausschnitt aus dem Modell. Bei der deterministischen Simulation dieses Modells ergab sich ein HIC(d) von 993. Ein so knappes Unterschreiten des Grenzwertes stellt offensichtlich ein sehr hohes Versagensrisiko dar, aus der deterministischen Simulation ist dies jedoch nicht quantifizierbar. In einem ersten Schritt wurde deshalb eine stochastische Simulation mit dem Modell durchgeführt, um die Versagenswahrscheinlichkeit abschätzen zu können. Dabei wurden sowohl Versuchsbedingungen als auch System-Parameter gestreut. Bei den Versuchsbedingungen kann die wichtigste Streuung direkt der Vorschrift FMVSS 201 entnommen werden: Die Aufprallgeschwindigkeit kann zwischen 23,3 und 23,9 km/h schwanken. Diese Streuung wurde in der stochastischen Analyse in Form einer gleichverteilten Variablen simuliert (vgl. /6/, S. 21).

Bei den Systemeigenschaften handelt es sich primär um Geometrie- und Materialkenngrößen, wie z.B. die Dicken von Blech- und Verkleidungsteilen und insbesondere der Rippen, die E-Moduli der verschiedenen Materialien und die Reibungskoeffizienten bei den Kontakten zwischen Kopfform und B-Säule.



**Abbildung 6: Kopfaufprallmodell**

Abbildung 7 zeigt die Verteilung des HIC(d)-Wertes, die sich aus einer Stichprobe von 50 Fällen ergibt. In über 40% der Fälle wird der Grenzwert überschritten. Es besteht also Handlungsbedarf hinsichtlich der Gestaltung der B-Säule.



**Abbildung 7: Verteilung des HIC(d)**

Neben der Information über die Versagenswahrscheinlichkeit liefert die Stochastische Simulation auch Erkenntnisse über die Korrelation, also die Stärke des Zusammenhangs zwischen Inputs und Outputs. Diese Information ist natürlich sehr nützlich, wenn es darum geht ein System zu verbessern. Im vorliegenden Fall zeigte sich, daß der Parameter, der am stärksten mit dem HIC(d)-Wert korreliert, die Aufprallgeschwindigkeit ist. Da dieser Wert jedoch nicht zur Verbesserung hergenommen werden kann, muß man sich auf die wichtigsten System-Parameter konzentrieren. Im vorliegenden Fall war der einzige Parameter, der stärker mit dem HIC(d)-Wert korrelierte, die Dicke einer Blecheinlage in der B-Säule. Dieser Parameter wurde deshalb als Design Parameter für die Verbesserung des Systems verwendet. Trotz recht schwacher Korrelation wurden darüber hinaus die Dicke der Verkleidungsrippen, die Dicke einer weiteren Blechverstärkung der B-Säule sowie das Material der Innenverkleidung (E-Modul) verwendet, da dies die einzigen Parameter waren die in dem vorliegenden Entwicklungsstadium noch änderbar waren.

Eine Verbesserung des Systems wurde mittels der oben beschriebenen Stepping Methode (siehe Abschnitt 2.3) vorgenommen. Neben den vier Design Parametern wurden die übrigen Parameter weiterhin als freie stochastische Variablen behandelt.

Schon in der zweiten Iteration konnte der Mittelwert des HIC(d)-Werts von 992 auf 936 gesenkt werden. Viel wichtiger als die Senkung des Mittelwerts ist jedoch die Senkung der Versagenswahrscheinlichkeit. Bei der verbesserten Lösung lag in einer Stichprobe von 50 Fällen kein einziger über dem Grenzwert. Um dieses Ergebnis zu erreichen genügten schon geringfügige Änderungen der Design-Parameter: Die Blechdicken müssen um 1/10 bzw. 2/10 mm geändert werden. Das Material der Innenverkleidung sollte einen um 10 % höheren E-Modul aufweisen, die Rippen müssen nicht geändert werden.

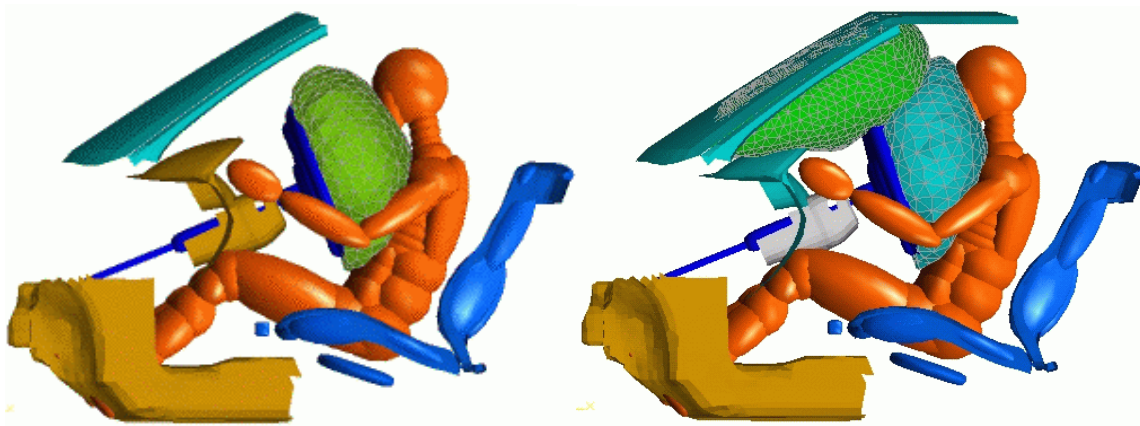
Das Beispiel zeigt, daß mit der Stepping Methode erhebliche Verbesserungen erzielt werden können und zwar unter Berücksichtigung von Streuung und Unsicherheiten. Ein Blick auf das Histogramm in Abbildung 7 zeigt, daß auch beim ursprünglichen System einzelne Fälle niedrigere HIC-Werte um 930 aufweisen. Dies sind jedoch unwahrscheinliche Ausnahmen. Erst die Veränderung der Design-Parameter führt zu einer wirklichen Verschiebung des Histogramms und somit zu einer verbesserten Lösung. Bei deterministischer Vorgehensweise läuft man dagegen oft Gefahr unwahrscheinliche Ausnahmen (oder gar echte Ausreißer) als „Optimum“ zu betrachten.

### 3.2 Beispiel 2: Verbesserung eines Rückhaltesystems

Auch das zweite Beispiel soll die Risiken einer deterministischen Vorgehensweise verdeutlichen. Es geht um die Gestaltung eines Fahrer-Airbagsystems. Dabei soll der in der US-Norm FMVSS 208 definierte Frontalcrash mit einer Geschwindigkeit von 30 mph und nicht angegurten Insassen betrachtet werden. Dieser Lastfall stellt besonders hohe Anforderungen an das Airbag-System, da die wichtige zusätzliche Rückhaltewirkung des Gurtes fehlt. Es besteht besonders die Gefahr des Durchschlagens des Insassen durch den Airbag, was zu harten Kontakten mit Lenkrad oder Windschutzscheibe führt. Um diese zu verhindern, müssen besondere Maßnahmen ergriffen werden, die insbesondere dazu dienen, den Airbag in einer günstigen Position zu halten. Mögliche Maßnahmen sind u.a. die Verwendung asymmetrischer Fangbänder die den Airbag nach unten ziehen sowie die exzentrische Montage des Airbag im Lenkrad. Dadurch wird einem nach oben Schieben des Airbags entgegengewirkt, um so Kontakt der Brust mit dem unteren Lenkradkranz zu verhindern. Bei deterministischer Betrachtung funktionieren diese Maßnahmen sehr gut. Aber es ist offensichtlich, daß sie keine robuste Lösung darstellen können. Wird nämlich das Lenkrad verdreht, bewirkt die asymmetrische Gestaltung natürlich genau das Gegenteil der gewünschten Wirkung. Selbst wenn die Streuung der Lenkraddrehung in Crashversuchen recht gering ist, so muß man bei Realunfällen mit sehr großer Streuung rechnen, da die meisten Unfallbeteiligten instinktiv versuchen durch Lenken den Unfall zu vermeiden. Insofern kann ein solches System zwar möglicherweise bei Crashversuchen gute Ergebnisse liefern, es sollte aber trotzdem nicht verwendet werden, da es nicht robust genug für das reale Unfallgeschehen ist.

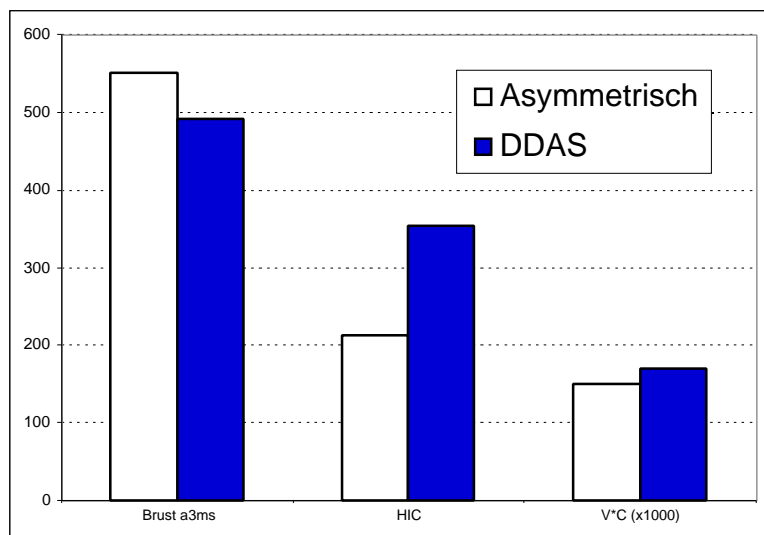
Eine alternative Lösung stellt ein Doppel-Airbag Konzept dar (DDAS: Driver Double Airbag System), das gemeinsam von EASi Engineering und Eyrainer Automotive Concepts entwickelt wurde. Hierbei kommt ein sehr einfacher Lenkrad-Airbag zum Einsatz, der zentrisch montiert ist und ohne Fangbänder auskommt. Zusätzlich wird ein zweiter Airbag in der Instrumententafel montiert, der sich zwischen Lenkrad-Airbag und Windschutzscheibe legt und so den Lenkrad-Airbag stützt und in Position hält (vgl. Abbildung 8). Außerdem deckt der Zusatzbag die Windschutzscheibe so ab, daß der Kopf nicht mehr dagegen schlagen kann. Das System ist aufgrund seiner Symmetrie unempfindlich gegen Verdrehen des Lenkrads.

Die beiden geschilderten Lösungskonzepte wurden mit dem Berechnungsprogramm MADYMO3D simuliert und verglichen. Abbildung 8 zeigt die beiden Modelle im Vergleich.



**Abbildung 8: Simulationsmodelle im Vergleich**

Vergleicht man die Ergebnisse deterministischer Analysen beider Modelle, zeigen sich anhand der ausgewählten Verletzungskriterien HIC, Brustbeschleunigung ( $a_{3ms}$ ) und Viscous Criterion ( $V^*C$ ) nur geringfügige Unterschiede (vgl. Abbildung 9).



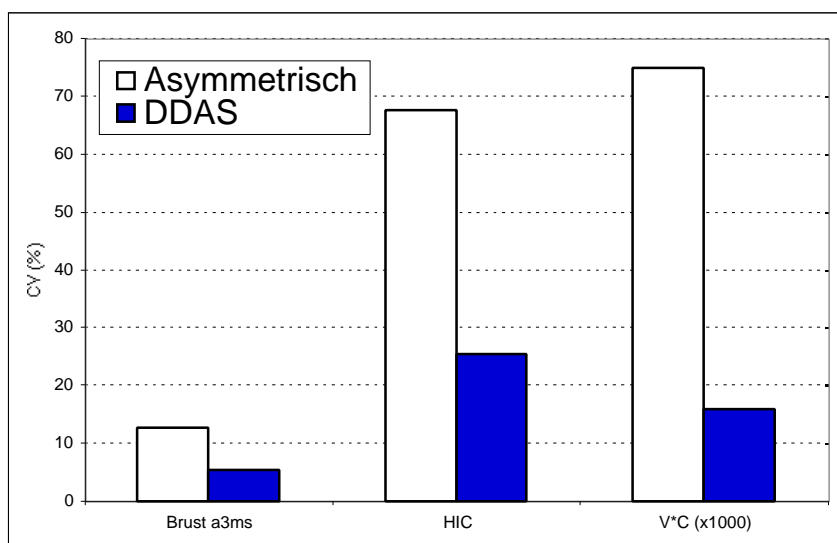
**Abbildung 9: Vergleich der deterministischen Ergebnisse**

Wesentlich interessanter ist jedoch der Vergleich der Streuung der Ergebnisse Stochastischer Simulationen beider Modelle. Mit beiden Modelle wurde eine solche stochastische Simulation mit jeweils 100 Fällen durchgeführt. Dabei wurden zahlreiche Systemparameter gestreut, wie z.B. die Sitzposition des Insassen, der Zündzeitpunkt des/der Airbags usw. Besonders interessant war natürlich die Streuung der Lenkraddrehung. Hier wurde ein Streubereich von  $\pm 180^\circ$  definiert. Zum Vergleich der Streuung mehrerer Modelle

und Variablen eignet sich besonders der Variationskoeffizient (CV), der definiert ist als Quotient aus Standardabweichung und Mittelwert.


$$CV = \frac{s}{\bar{x}} = \frac{\text{Standardabweichung}}{\text{Mittelwert}} \quad (2)$$

Er normiert die Streuung auf den Mittelwert und erlaubt so den Vergleich der Streuung selbst bei stark unterschiedlichen Mittelwerten. Üblicherweise wird der Variationskoeffizient als %-Wert angegeben. Abbildung 10 zeigt den Vergleich der Variationskoeffizienten beider Konzepte. Das Doppel-Airbag Konzept weist eine deutlich geringere Streuung auf und ist somit wesentlich robuster als die asymmetrische Lösung.



**Abbildung 10: Vergleich der Variationskoeffizienten**

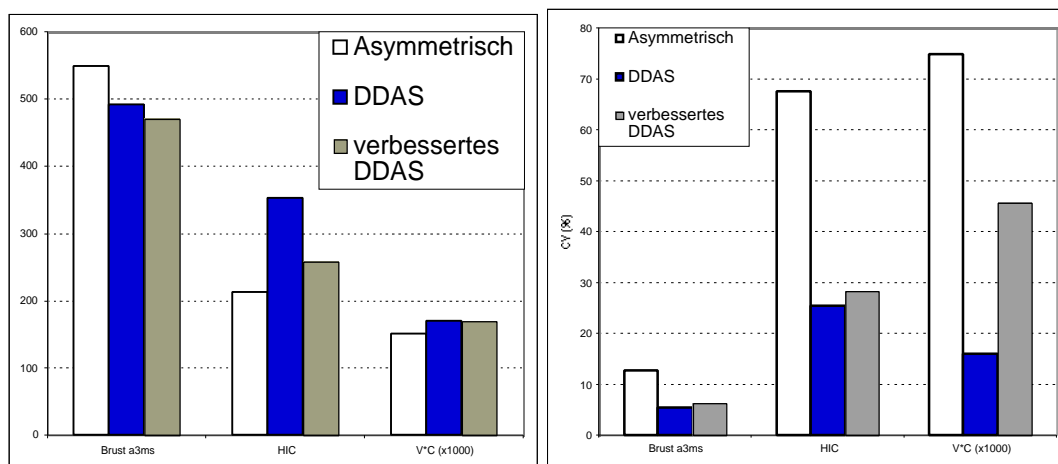
Abbildung 11 zeigt am Beispiel des V\*C Wertes den Effekt der Lenkraddrehung beim asymmetrischen Airbag. Der Kreis bei einem Winkel von 0° zeigt das deterministische Ergebnis zum Vergleich. Man erkennt, daß die deterministische Lösung fast den günstigsten Fall darstellt, bei dessen alleiniger Betrachtung die Gefahr einer zu optimistischen Bewertung besteht.



**Abbildung 11: V\*C in Abhängigkeit vom Lenkradwinkel**

Im nächsten Schritt wurde das Doppel-Airbag Konzept mit Hilfe der Stepping Methode weiter verbessert. Als Design-Parameter wurden die Geometrie des Zusatz-Airbags, die Leistung der Gasgeneratoren, das Ausströmverhalten und die Zündzeitpunkte beider Airbags verwendet. Die übrigen Parameter wurden weiterhin als freie stochastische Variablen behandelt.

Nach drei Iterationen wurde eine verbesserte Lösung gefunden, die auch hinsichtlich der Robustheit akzeptabel war. Abbildung 12 zeigt links die deterministischen Ergebnisse der verbesserten Lösung im Vergleich mit dem ursprünglichen Modell und dem Asymmetrischen Airbag. Rechts sind die Streuungen im Vergleich dargestellt. Man erkennt eine Verbesserung der Ergebnisse, aber auch eine leichte Zunahme der Streuung insbesondere beim Viscous Criterion.



**Abbildung 12: Verbesserte Lösung im Vergleich**

Interessanterweise ergaben sich bei weiteren Iterationen zwar teilweise deutlich bessere Einzelergebnisse, die Streuung der Ergebnisse innerhalb nahm jedoch so stark zu, daß die

Lösungen nicht akzeptiert werden konnten. Hier zeigt sich der große Vorteil des Konzepts der Stochastischen Verbesserung: Das Verfahren liefert gleichzeitig Informationen die eine fundierte Bewertung der Ergebnisse ermöglichen. Das Risiko instabile Lösungen auszuwählen, wie sie bei klassischen Optimierungsmethoden fast zwangsläufig generiert werden, wird eliminiert. Man erkennt bei den Ergebnissen unmittelbar, ob es sich um Ausreißer, oder um robuste, streuungsunempfindliche Lösungen handelt.

#### **4 Zusammenfassung und Ausblick**

Stochastische Simulationen haben heute den Weg in die industrielle Produktion gefunden. Sie werden im Automobilbau erfolgreich in den Bereichen Crash, Safety und NVH eingesetzt. Zusammen mit deterministischen Simulationen und einer starken Einbindung des Versuches erlauben sie erstmals die hohen Erwartungen an die rechnergestützte Produktentwicklung zu erfüllen.

Durch den Einsatz der Stochastischen Simulation auch in der Simulation von Produktionsabläufen, z. B. Tiefzieh- oder Spritzgußsimulationen sind die Voraussetzungen geschaffen um in Zukunft Qualitätsvorhersagen für Produkte abzugeben. Damit eröffnet sich, durch die Möglichkeit die Robustheit eines Produktes über die Streubreite der Produkt- und Produktionsparameter zu kontrollieren, ein großes Potential zur Kostenreduktion ohne Einschränkungen bei Performance und Robustheit.

#### **5 Literatur**

- /1/ Storath, E. u.a.: *Das virtuelle Produkt im Prozeßnetz – mehr als nur die Anwendung von Systemen entlang der Prozeßketten*. In: VDI Gesellschaft Entwicklung Konstruktion Vertrieb (Hrsg.): *VDI Berichte 1435 – Prozessketten für die virtuelle Produktentwicklung in verteilter Umgebung*. Düsseldorf 1998, S. 169-181.
- /2/ Marczyk, J.: *Principles of Simulation Based Computer-Aided Engineering*. FIM Publications, Barcelona 1999.

- /3/ ST-ORM, A Meta-Computing System for Stochastic Optimization and Robustness Management, EASi Engineering GmbH, 2000
- /4/ Doltsinis, I./Rau, F./Werner M.: *Analysis of random systems*. In: Doltsinis, I. (Hrsg.): *Stochastic Analysis of Multivariate Systems in Computational Mechanics and Engineering*. CIMNE, Barcelona 1999, S. 9-159.
- /5/ Reuter, R./Gärtner, T.: *Stochastische Crashsimulation mit LS DYNA am Beispiel des Kopfaufpralls nach FMVSS 201*. 17. CAD-FEM Users' Meeting, Sonthofen 1999.
- /6/ Reuter, R./Hülsmann, J.: *Achieving Design Targets through Stochastic Simulation*. 8<sup>th</sup> International MADYMO Users Conference, Paris 2000
- /7/ U.S. Department of Transportation – NHTSA: *Laboratory Test Procedure for FMVSS 201 – Occupant Protection in Interior Impact / Upper Interior Head Impact Protection*. U.S. DOT TP-201U-00.