

Vorträge

Der Abgleich von Messung und Simulation als Optimierungsaufgabe

Johannes Will

Der Abgleich von Messung und Simulation als Optimierungsaufgabe

Johannes Will

DYNARDO GmbH, Weimar, Germany

Zusammenfassung:

Der Abgleich zwischen Messung und Nachrechnung gehört zu den klassischen Aufgabenstellungen einer Modellvalidierung. Ist die Differenz zwischen Messung und Nachrechnung zu groß, kann daraus eine Optimierungsaufgabenstellung der Minimierung der Differenzen formuliert werden. Optimierungsaufgabenstellungen des Abgleichs zwischen Messung und Nachrechnung werden häufig als Identifikationsproblem bezeichnet. In der Vergangenheit wurde diese Aufgabenstellung i.d.R. durch iterative Anpassung einzelner Kennwerte bearbeitet. Mit der Verfügbarkeit von Parameteroptimierungsprogrammen kann der iterative händische Abgleich automatisiert werden und es können komplexere Aufgabenstellungen bearbeitet werden. Die Notwendigkeit derart automatisierter Identifikationsprozeduren wird auch durch die Innovationsgeschwindigkeit in heutigen Produktentwicklungsprozessen erhöht. Innerhalb des Virtual Prototyping ist Virtual Testing dabei der Schlüssel zur Reduktion von Hardwaretests. Nur wenn an Referenzexperimenten ein Abgleich wichtiger Ergebnisgrößen zwischen Messung und Simulation gelingt, kann davon ausgegangen werden, dass alle für das reale Testergebnis relevanten Phänomene im virtuellen Modell enthalten sind und damit prognosefähige Modelle für das Virtual Testing zur Verfügung stehen.

In der Veröffentlichung wird ein kurzer Überblick über Methoden der Sensitivitätsstudien und Optimierungsstrategien gegeben. An praktischen Aufgabenstellungen wird deren Eignung für eine möglichst automatisierte Identifikation diskutiert.

Keywords:

System Identifikation, Optimierung, Sensitivitätsstudie, statistische Methoden

1 Einleitung

Am Beginn des Abgleich wird immer der Vergleich zwischen Ergebnissen der Messung und den dazugehörigen Ergebniswerten des numerischen Modells stehen. Wenn die Differenz zu groß ist, kann die Suche nach einem besseren Abgleich als Optimierungsaufgabenstellung formuliert werden. Die „Optimierungsvariablen“ sind dann diejenigen Kennwerte des numerischen Modells in denen Unterschiede zwischen Messung und Nachrechnung vermutet werden beziehungsweise deren Werte unbekannt oder unsicher sind. Dann wird in einem Designraum, welcher durch variierende „Eingangsvariablen“ der numerischen Modelle definiert ist, mittels Optimierungsverfahren ein Abgleich zwischen Simulation und experimentellen Ergebnis gesucht. Eine solche Aufgabenstellung stellt spezielle Anforderungen an die Optimierungsmethodik, die im ersten Teil der Veröffentlichung diskutiert werden.

Die Komplexität einer solchen Aufgabenstellung variiert vom Abgleich eines Kennwertes bis zur Identifikation unbekannter Systemeigenschaften. Während der Abgleich einzelner Ergebnisgrößen durch das „Einstellen“ einzelner Kennwerte jedem Berechnungsingenieur wohl vertraut ist, können Identifikationsaufgabenstellungen ungekannter Kennwertsätze und damit verbundener Systemeigenschaften sehr komplex werden.

Bei stark streuenden Messergebnissen kommt hinzu, dass der Abgleich mit Einzelwerten an Aussagekraft verliert. Muss davon ausgegangen werden, dass die Streuung in den Messergebnissen auch in Natura zu erwarten ist, stellt sich die Frage, welches der möglichen Messergebnisse abzugleichen ist. Ein erster Schritt die Streuung von Ergebnisgrößen zu berücksichtigen, ist die Mittelung der streuenden Größen zu einem Mittelwertsatz. Dann wird zumindest gesichert, dass der Abgleich zum Erwartungswert (Mittelwert) durchgeführt wird und die Prognosefähigkeit im Mittel gegeben ist. Ein Abgleich mit Mittelwerten der Messung reicht dann nicht mehr aus, wenn die Prognosefähigkeit der Simulation über den erwarteten Streubereich gesichert werden soll. Dann sollten Validierungen auch an den zu betrachtenden Intervallgrenzen der Ergebnisgrößen durchgeführt werden.

Natürlich beinhaltet die beobachtete Streuung der Ergebnisgrößen, außerhalb der Fragestellung der Prognosefähigkeit aller möglichen Ergebnisse, wichtige Informationen über in Natura zu erwartende Streuungen. Derartige Angaben über zu erwartende Eingangsstreuungen die zu beobachteten Ausgangsstreuungen führen werden z.B. für Robustheitsbewertungen in der virtuellen Produktentwicklung [9] benötigt. Die Aufgabenstellung erweitert sich dann um die Identifikation der statistischen Eigenschaften der mit den Ausgangsstreuungen verbundenen Eingangskennwerte. Hier müssen streng genommen statistische Maße streuender Eingangs- und Ausgangsgrößen abgeglichen werden. Soll die Prognosefähigkeit eines Streubereiches einer Ergebnisgröße gesichert werden, würde die Identifikation der zugehörigen Streubereiche der für die Ausgangsstreuung verantwortlichen streuenden Eingangsgrößen genügen. Wenn allerdings auch Aussagen über Wahrscheinlichkeiten des Überschreitens von Grenzwerten der Ergebnisgrößen von Interesse sind müssen die Verteilungsfunktionen der Eingangsvariablen, die zu den beobachteten Ausgangsstreuungen führen, identifiziert werden. Im Extremfall bedeutet das, dass die Identifikation von n-Kennwertsätzen zu n-Versuchsergebnisse durchzuführen ist. Die Histogramme der n-identifizierten Kennwerte jedes Kennwertes bilden dann die Grundlage der Verteilungsfunktionen.

Aus unseren praktischen Erfahrungen liegt der Schlüssel zum Erfolg einer Identifikation neben leistungsfähigen Algorithmen der Optimierung häufig in der Definition des Designraumes sowie der Zielfunktion. Eine Erfolg versprechende Optimierungsaufgabenstellung lässt sich häufig nur formulieren, wenn der Designraum aus zu wichtigen Ergebnisgrößen sensiblen Parametern zusammengestellt werden kann. Deshalb ist zu empfehlen, vor einer Optimierung eine Sensitivitätsanalyse des potentiellen Designraum durchzuführen und den Kennwertsatz auf zu den wichtigen Ergebnisgrößen sensible Parameter zu beschränken. Es sei darauf hingewiesen, dass bei Identifikationsproblemen manchmal das Phänomen zu beobachten ist, dass mit steigender Anzahl von Optimierungsvariablen die Abgleichsgüte nur auf den ersten Blick besser wird. Der Optimierer kann zwar durch zusätzliche Freiheitsgrade das Zielfunktional besser minimieren, liefert aber eine Vielzahl von Kennwerten, die zufällige Werte annehmen. Eine Übersetzung des Kennwertsatzes in physikalisch plausible Kennwerte beziehungsweise die „Filterung“ zwischen identifizierten Kennwerten und zufälligen oder „verstellten“ Kennwerten ist nicht trivial. Deshalb ist häufig ein 90% Abgleich mit wenigen physikalisch sinnvoll identifizierten Kennwerten besser als ein 95% Abgleich mit einer Vielzahl zufälliger oder verstellter Parameter.

Gleichzeitig sollte innerhalb der Sensitivitätsanalyse überprüft werden, ob das abzugleichende Ereignis sich überhaupt im Designraum des virtuellen Modells befindet. Kann mit hoher Wahrscheinlichkeit davon ausgegangen werden, dass das abzugleichende Messergebnis außerhalb des Variationsraumes der Sensitivitätsstudie liegt, sollten die Ursachen diskutiert werden. Entweder es lassen sich weitere Unterschiede zwischen Messung und Simulation identifizieren und als „Optimierungsvariable“ gewinnen oder das numerische Modell enthält die dem Messergebnis zugrunde liegenden Wirkmechanismen nicht oder das Messergebnis ist fehlerbehaftet.

2 Sensitivitätsstudien

Um zu überprüfen, ob der Designraum aus „sensiblen“ zu identifizierenden Parametern gewählt worden ist und ob ein Abgleich mit Messergebnissen in diesem Designraum realistisch erscheint, sind Sensitivitätsstudien zu empfehlen. 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 der Sensitivitäten mittels Korrelationsanalyse (welche Optimierungsvariablen wirken wie auf welche Ergebnisgrößen) und Variationsanalyse (Schätzen der möglichen Variation der abzugleichenden Ergebnisse im gewählten Designraum) erlauben. Wichtigste statistische Größe für die Sensitivität der Optimierungsvariablen auf wichtige Ergebnisgrößen kann das Bestimmtheitsmaß herangezogen werden. So zeigt das Bestimmtheitsmaß in Abb. 1 beispielsweise an, dass 95% der Variation der maximalen Kraft in Section35 aus linearen Zusammenhängen resultieren und die „sensibelsten“ Eingangsvariablen die Fließspannung sowie die Dicke von zwei Blechen (Part 1007 und Part 1009) sind. Damit lässt sich der Unterraum der Identifikation dieses Ergebniswertes auf die vier sensiblen Parameter begrenzen. Im Histogramm ist abzulesen, dass die Ergebnisgrößen im Designraum mindestens zwischen 69515 N bis 85756 N variiert. Wenn das zu identifizierende Messergebnis in diesem Variationsraum liegt, kann mit hoher Wahrscheinlichkeit davon ausgegangen werden, dass ein Abgleich im Unterraum der 4 sensiblen Kennwerte möglich ist. Für eine Beschreibung weiterer statistischer Maße sei auf [10] verwiesen.

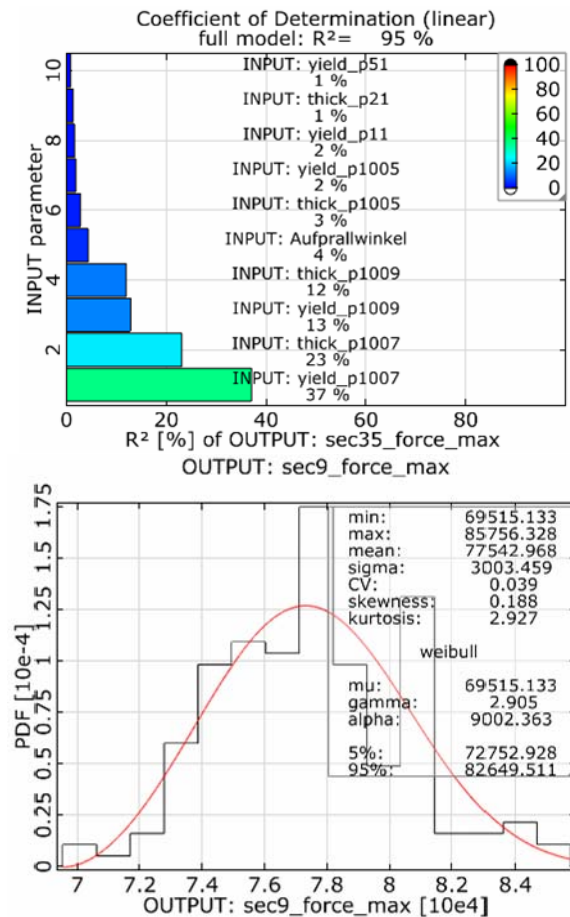


Abb. 1 Bestimmtheitsmaße und Histogramm einer Ergebnisgröße

Damit ermöglichen Sensitivitätsstudien eine Reduktion des Parameterraumes für anschließende Optimierungsaufgabenstellungen. Das Vorwissen aus den Sensitivitätsstudien über Eigenschaften des Designraumes ist darüber hinaus für eine geeignete Formulierung von Nebenbedingungen und Zielfunktionen sehr hilfreich. Aus den Durchrechnungen der Sensitivitätsstudien können geeignete Startpunkte einer Gradientenoptimierung, geeignete Startapproximationsräume adaptiver Response Surface Methoden oder Eingangsinformationen für Startgenerationen evolutionärer Suchstrategien gewonnen werden.

3 Lösen des Identifikationsproblems mittels Optimierungsverfahren

Zur Bearbeitung des Optimierungsproblems stehen grundsätzlich mindestens drei Verfahrensklassen zur Auswahl: mathematische Optimierungsverfahren mittels Gradienten (Gradientenverfahren), Response Surface Methoden (RSM) und stochastische Suchstrategien.

3.1 Mathematische Optimierungsverfahren mittels Gradienteninformationen

Mathematische Optimierungsverfahren [7], 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. Idealerweise sollten Gradientenverfahren in der Nähe des Optimum (des Abgleichs) starten. Deshalb werden Gradientenverfahren häufig verwendet, um zu prüfen, ob voroptimierte Parametersätze noch verbessert werden können.

3.2 Response Surface Methoden

Wenn die Anzahl der Optimierungsvariablen auf wenige Variablen (5...15) begrenzt werden kann, bieten Response Surface Methoden [4] 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 (ARSM), die den Approximationsraum solange zoomen und verschieben bis das Optimum auf der Response Surface konvergiert, am erfolgreichsten [8]. Die kritische Größe aus Sicht praktischer Anwendung ist vor allem die Anzahl der Optimierungsvariablen. Deshalb werden Response Surface Methoden in kleinen Dimensionen der sensibelsten Optimierungsvariablen, die zuvor mit Sensitivitätsstudien ermittelt worden sind, eingesetzt. Solcherart voroptimierte Design können dann als Startpunkt einer Gradientenoptimierung oder als Eingangsinformation evolutionärer Suchstrategien eingesetzt werden.

3.3 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 [1] und evolutionäre Strategien [6] am erfolgreichsten sind. Der Begriff stochastische Suchverfahren wird hier verwendet, weil „zufällige“ Ereignisse zur Designveränderung führen. 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 als „globale“ Suche eines möglichen Abgleichs eingesetzt werden. Evolutionäre Strategien eignen sich besonders gut, wenn ein geeignetes Vorwissen in den Startgenerationen vorhanden ist. Ausgehend von voroptimierten Design aus genetischen Suchstrategien oder ARSM-Läufen können mittels evolutionärer Strategien lokale Optimierungen zur Feinabstimmung durchgeführt werden. Abhängig von den Einstellungen der Austausch- und Mutationsoperatoren können Mischformen zwischen genetischen und evolutionären Suchstrategien eingestellt und dann für kombinierte globale und lokale Optimierung verwendet werden.

4 Anwendungen

In der Folge sollen an praktischen Anwendungsbeispielen potentielle Einsatzgebiete von Optimierungsverfahren für den Abgleich zwischen Messung und Nachrechnung aufgezeigt werden. In allen Anwendungen wurde für die Optimierung die Software OptiSLang [5] bzw. die dort implementierten Algorithmen verwendet.

4.1 Identifikation des dynamischen Verhaltens von Glockentürmen [11]

Glockentürme historischer Kirchen sind ein gutes Beispiel für Strukturen, deren dynamisches Verhalten unbekannt ist. Wichtigste dynamische Anregung der Strukturen ist das Läuten der Glocken. Bei der Sankt Michael Kirche in Jena wurde mittels dynamischer Messungen die Stabilität des Glockenturmes unter dem Lastfall „Läuten der Glocken“ untersucht. Weiterhin wurde die Sanierung des Glockenturmes mittels Messung und Nachrechnung begleitet und überprüft ob die Sanierungsmaßnahmen zur gewünschten Ertüchtigung des Glockenturmes beitragen.

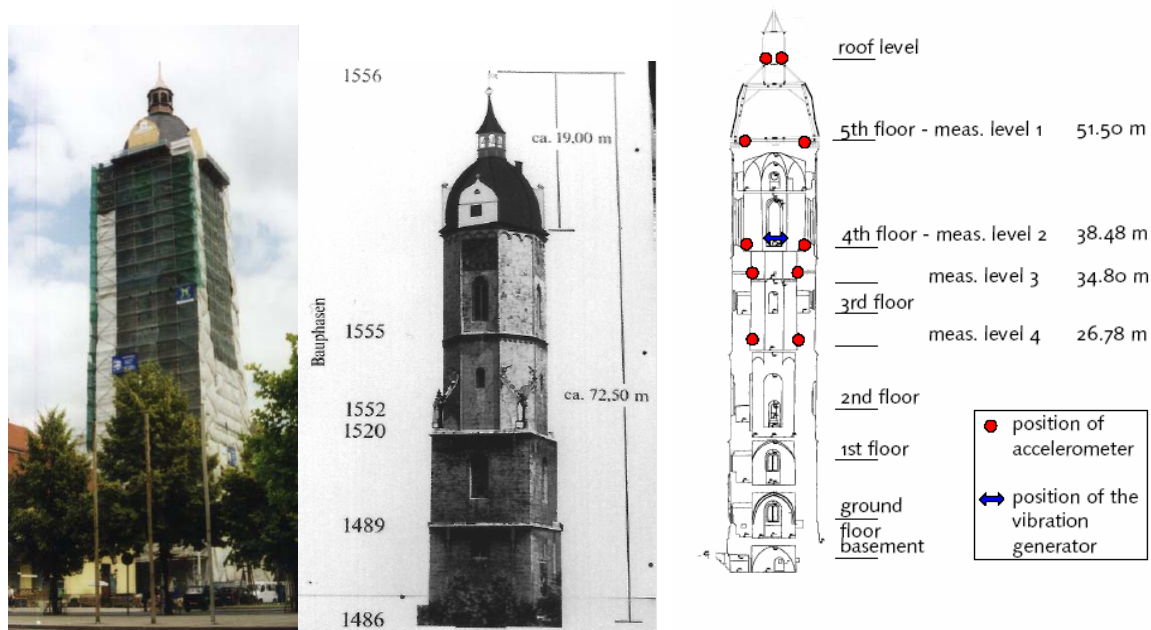


Abb. 2. Links-Glockenturm in der Sanierung, Mitte-Baugeschichte, Rechts-Positionen des Vibrators und der Messstellen

Der Glockenturm wurde mittels servo-hydraulischen Vibrationsgenerator dynamisch angeregt. Die Geschwindigkeitssignale wurden auf verschiedenen Ebenen aufgenommen und aus dem Abgleich zwischen den Übertragungsfunktionen der Messergebnisse und dem numerischen Modell wurden Eigenfrequenzen und Eigenformen identifiziert.

Für den Abgleich des unsanierten Glockenturmes wurden 39 Kennwerte (Elastizitätsmoduli, Rohdichten, Querdehnraten, Steifigkeiten von Verbindungen/Verbindungsmitteln und modale Dämpfungsfaktoren) variiert. Die Zielfunktion wurde aus Differenzen in den Eigenfrequenzen und Eigenformen (über einen MAC-Abgleich) definiert. Als Optimierungsverfahren wurde ein genetischer Optimierungsalgorithmus verwendet. Es wurden verschiedene Kombinationen der Zielfunktionsdefinition verwendet, die alle zu ähnlichen Abgleichsniveaus (siehe Abb. 4) führen. Bei allen Varianten der Zielfunktion konnte die Frequenz des zweiten Modes nicht gut abgeglichen

werden. Beim dritten bis fünften Mode ist der Abgleich mäßig erfolgreich und stark vom Zielfunktional abhängig, was darauf schließen lässt, dass deren Gewicht in der Zielfunktion im Vergleich zum ersten und zweiten gering ist.

The finite element model

- 784 elements (mainly 8-node brick elements)
- 1458 nodes with 4337 active DOF
- approximation of vaults by plain slabs
- 12 groups of elements
- influence of church house modelled by spring elements




Abb. 3 Finite Element Modell

Model updating - structure before retrofit

- natural frequencies [Hz]

Mode	identified	result - criterion 1	result - criterion 2	result - criterion 3
1	1.47	1.449	1.396	1.432
2	1.54	1.468	1.470	1.470
3	4.51	4.450	4.104	4.305
4	4.77	4.499	4.406	4.532
5	5.05	5.074	5.058	4.926

- frequency response functions



Abb. 4 Abgleich unsanierter Glockenturm

Für den Abgleich des sanierten Turmes wurden 60 Kennwerte variiert. Die Zielfunktion wurde aus Differenzen der Eigenwerte und Eigenformen definiert. Im ersten Fall (model1) wurden nur der erste und zweite Eigenmode abgeglichen, im zweiten Fall (model2) wurden die ersten 5 Eigenformen abgeglichen. Es konnte gezeigt werden, dass ein Abgleich der Eigenfrequenzen und Eigenformen 1 bis 4 möglich ist, aber im definierten Designraum mit den gewählten Zielfunktionen Konflikte existieren (siehe Abb. 5). Ein zufrieden stellender Abgleich aller 4 ersten Eigenformen mit einem Kennwertsatz konnte nicht erzielt werden.

Model updating - structure after retrofit

- comparison of natural frequencies and mode shapes

identified nat. freq. [Hz]	description	nat. freq. model 1 [Hz]	description	nat. freq. model 2 [Hz]	description
1.506	1st bending mode in SE-NW direction	1.512	1st bending mode in SE-NW direction	1.674	1st bending mode in SE-NW direction
1.588	1st bending mode in SW-NE direction	1.562	1st bending mode in SW-NE direction	1.719	1st bending mode in SW-NE direction
4.78	2nd bending mode in N-S direction & torsion	3.931	torsion	4.790	2nd bending mode in N-S direction & torsion
5.18	2nd bending mode in E-W direction & torsion	4.555	2nd bending mode in SW-NE direction	5.268	2nd bending mode in E-W direction & torsion
5.53	torsion	4.759	2nd bending mode in SE-NW direction	5.379	2nd bending mode in SE-NW direction

Abb. 5 Abgleich sanierter Glockenturm

Aus Sicht der Autoren von [11] konnte mittels der Identifikation die primäre Aufgabenstellung nachgewiesen werden, dass die Sanierungsmaßnahme die dynamische Tragfähigkeit signifikant erhöht hat und dass die Eigenfrequenzen der Glocken einen ausreichenden Abstand zu den Eigenwerten des Turmes haben.

Bei der Definition des Designraumes, der Definition der Zielfunktion sowie beim Optimierungsalgorithmus wird Verbesserungspotential gesehen. Wahrscheinlich ist allerdings auch mit erhöhtem Aufwand in der Zielfunktionsbeschreibung und den Optimierungsalgorithmen im gewählten Designraum kein wesentlich besserer Abgleich zu erreichen. Angesichts der unbekanntenen mechanischen Eigenschaften der Mauerwerksstrukturen historischer Glockentürme erscheint es Erfolg versprechend die FEM-Modellierung des Glockenturmes für Eigenschaften, deren Abgleich unbefriedigend ist, gezielt zu verbessern. Um die Eignung des Unterraums für die Identifikation zu überprüfen, werden Sensitivitätsstudien unter Berücksichtigung aller potentiell unterschiedlichen Kennwerte empfohlen.

4.2 Identifikation von Materialkennwerten für viskoelastische Klebstoffe in der Automobiltechnik [2]

Für die Simulation viskoelastischer Klebstoffe für Klebeverbindungen elektronischer Bauteile werden Materialmodelle benötigt, welche über einen Temperaturbereich von -40 bis 150 °C die Abhängigkeit der mechanischen Eigenschaften der Klebeverbindung von Belastungsgeschwindigkeit und Belastungsdauer berücksichtigen können.




Abb. 6 Klebeverbindung elektronischer Bauteile

Für die Klebemittel werden DMA (dynamisch mechanische Analyse)-Mastermessungen sowie Relaxations- und Kriechversuche durchgeführt. Die Messungen werden im Frequenzbereich von 0.1 bis 100 Hz sowie im Temperaturbereich von -40 bis 150 °C durchgeführt. Das Materialmodell für die Simulation wird über einen PRONY-Reihenansatz mit insgesamt 52 zu identifizierenden Kennwerten beschrieben. Zur Nachrechnung der Versuche wurde ein mathematisches Modell in einer Fortranprogrammierung mit einer geringen Rechenzeit verwendet. Als Zielfunktion wird die Integralsumme der quadratischen Abweichungen zwischen Messung und Nachrechnung verwendet. Zusätzlich sind Energie erhaltende Randbedingungen strikt einzuhalten. Aus Sicht der Autoren [2] ist das Optimierungsproblem durch eine schlechte Konvergenz der Anpassung wegen vieler lokaler Minima gekennzeichnet. Für den Abgleich wurden deshalb genetische Optimierungsstrategien. Bekanntermaßen sind genetische Suchstrategien geeignet, um in Designgebieten mit vielen lokalen Optima möglichst globale „Optima“ zu suchen. Die Identifikation soll als automatisierte Routine standardmäßig zur Identifikation der Materialkennwerte eingesetzt werden. Wichtigste Anforderung an den Optimierungsalgorithmus war deshalb mit einer optimierten Einstellung der evolutionären Parameter möglichst robust einen guten Abgleich für verschiedene Kleber zu finden. Mit einer genetischen Optimierungsstrategie konnte diese Randbedingung erfüllt werden und es wurde ein Abgleich gefunden, der besser als der bisher von Hand erzielte war.




Abb. 7 Abgleich zwischen Messung und Nachrechnung mittels automatisierter genetischer Optimierungsstrategie

Mit einer Kopplung des genetischen Algorithmus mit einem nachlaufenden gradientenbasierten mathematischen Algorithmus konnte der Abgleich weiter verbessert werden. Damit konnte der Vorteil des genetischen Algorithmus robust in die Nähe des globalen Optima zu gelangen und der Vorteil mathematischer Optimierungsalgorithmen schnell zu konvergieren, wenn in der Nähe des Optima gestartet werden kann, erfolgreich verknüpft werden.

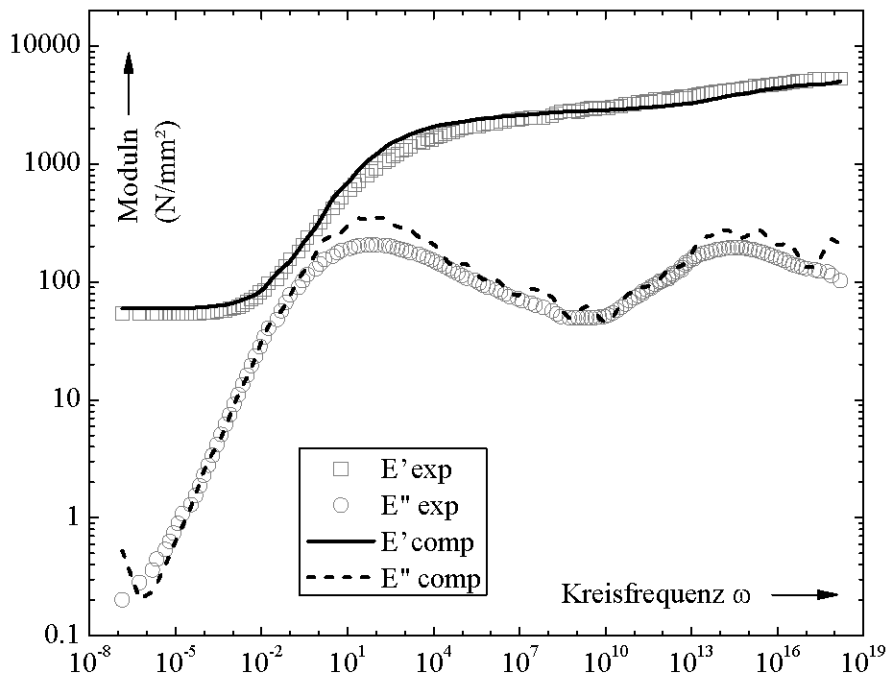


Abb. 8 Abgleich zwischen Messung und Nachrechnung mittels automatisierter genetischer Optimierungsstrategie und folgender gradientenbasierter mathematischer Optimierung

Die automatisierte Identifikation der PRONY-Komponenten konnte erfolgreich in den Regelprozess integriert werden. Mittels der automatisierten Identifikationsrechnung werden die Kennwerte für eine Materialroutine für das FEM Programm Abaqus zur Nachrechnung von Bauteilbelastungen bereitgestellt. Damit konnte der zuvor notwendige Aufwand einer schrittweise händischen Anpassung einzelner PRONY-Koeffizienten wesentlich verringert werden und ein besserer Abgleich erzielt werden.

4.3 Automatische Validierung von Airbagmodellen [3]

Zur Sicherung der Prognosefähigkeit numerischer Berechnungsmodelle von Airbags werden die Airbagmodelle mittels Nachrechnung von mehreren Konfigurationen von Komponentenversuchen validiert. In Abb. 9 ist eine Konfiguration eines Impaktorversuchs und der resultierende Beschleunigungsverlauf zu sehen. Die Impaktorversuche wurden mehrfach mit identischen Konfiguration durchgeführt und die streuenden Ergebniswerte wurde gemittelt. Die Validierung erfolgt dann gegenüber dem Erwartungswert (Mittelwert) des Versuches. Die Nachrechnung der Komponentenversuche erfolgt mit MADYMO.




Abb. 9: Versuchsaufbau (links) und Beschleunigungsverlauf (rechts)

Der Designraum des Abgleichs wird durch insgesamt 6 Parameter, der Gastemperatur, der Permeabilität sowie der Größe und Effizienz der Airbagöffnung beschrieben. Wichtige Bewertungsgrößen sind das Beschleunigungs-, das Weg- und das Drucksignal. Es werden die Maxima, die Zeitpunkte der Maxima und die Abweichung des zeitlichen Verlaufes betrachtet. Im Vorfeld wurde eine Sensitivitätsstudie durchgeführt, bei der die Matrix der linearen Korrelationskoeffizienten ausgewertet wurde. Die wesentlichen linearen Zusammenhänge zwischen Gastemperatur, Nahtpermeabilität und Effizienz der Airbagöffnung zu den Ergebnisgrößen sind physikalisch plausibel und entsprechen den Erwartungen. Die anderen Parameter des Designraumes zeigen keine signifikanten Zusammenhänge zu den Ergebnisgrößen und werden deshalb in der folgenden Identifikation nicht variiert. Weiterhin konnte gezeigt werden, dass die gemittelten Messkurven innerhalb der Kurvenscharen der Sensitivitätsstudie liegen. Damit kann erwartet werden, dass ein Abgleich mittels eines möglichst automatisierten Optimierungsverfahren möglich ist.

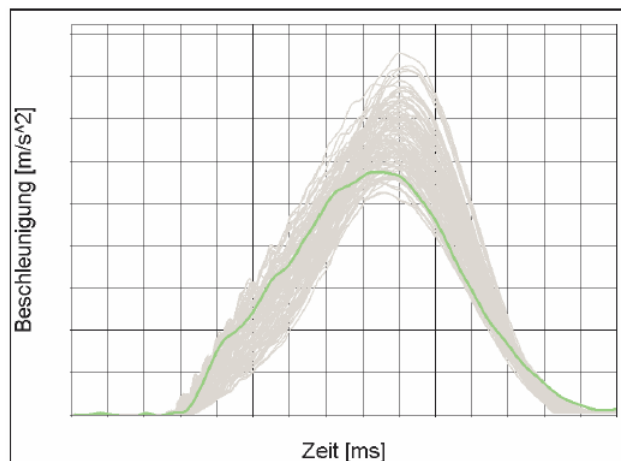


Abb. 10 Grau- 100 Durchrechnungen der Sensitivitätsstudie, grün- Mittelwertkurve des Versuches

Die Zielfunktion der Optimierung wird aus der Abweichung des Beschleunigungsverlaufes über die Zeit, dem Maximalwert der Beschleunigung sowie mit geringerer Wichtigung aus der Abweichung des Druckverlaufes über die Zeit zusammengesetzt [3]. Wegen der Unempfindlichkeit gegenüber lokalen Optima wird ein genetischer Optimierungsalgorithmus verwendet. Bei einer Populationsgröße von 10 Individuen und 15 Generationen a 7 Versuchskonfigurationen ergeben sich 1050 Durchrechnungen. Bei einer Simulationszeit von 3 Minuten pro Versuchskonfiguration und 5 Rechnungen parallel, dauert die gesamte Optimierung 11 Stunden.

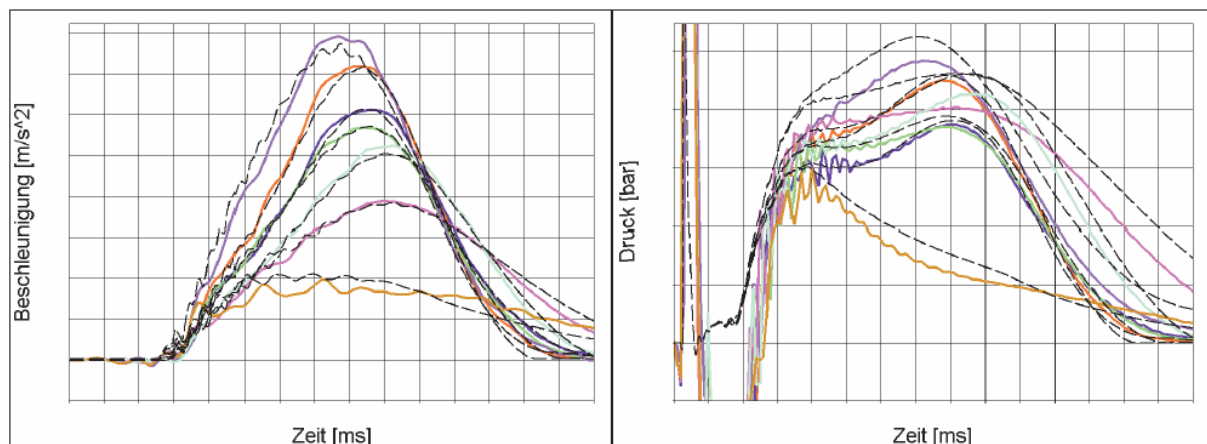


Abb. 11 Vergleich der Beschleunigungs- und Druckverläufe aus Versuch (farbig, durchgezogen) und Berechnung (schwarz, gestrichelt)

Abbildung 8 zeigt die Berechnungsergebnisse des optimalen Designs im Vergleich mit den Versuchsdaten. Sowohl die Übereinstimmung der Beschleunigungen, als auch die Übereinstimmung

der Drücke kann als sehr gut bezeichnet werden. Die automatisierte Validierung der Airbagmodelle soll auf weitere Airbagmodelle und komplette Rückhaltesysteme übertragen werden. Bei zunehmender Anzahl möglicher Parameter des Designraumes steigt die Bedeutung der Sensitivitätsstudie zur Reduktion der zu identifizierenden Parameter und zur Überprüfung der Eignung des Designraumes für den angestrebten Abgleich. Bei zunehmenden Rechenzeiten der Validierung kompletter Rückhaltesysteme soll darüber hinaus geprüft werden inwieweit adaptive Response Surface Methoden zur Reduktion des Berechnungsaufwandes beitragen können.

5 Zusammenfassung

Aufgabenstellungen der Identifikation beziehungsweise der Abgleichs zwischen Messung und Simulation werden heute in zunehmendem Maße mit Optimierungsalgorithmen bearbeitet. Dabei zeichnen sich genetische und evolutionäre Optimierungsstrategien durch ihre Robustheit für eine globale Suche eines bestmöglichen Abgleichs aus. Gradientenbasierte Optimierungsstrategien eignen sich sehr gut, wenn in der Nähe des Optima gestartet werden kann und damit für das Feintuning voroptimierter Parametersätze. Response Surface Strategien bieten darüber hinaus in kleinen Parameterräumen attraktive Alternativen.

Neben der Wahl des Optimierungsalgorithmus ist für Identifikationsaufgabenstellungen die Definition des Designraumes der Abgleichssuche von entscheidender Bedeutung. Hier werden Sensitivitätsstudien empfohlen, um möglichst sensitive Kennwerten zu identifizieren und zu prüfen, ob der Designraum den Abgleich zulässt. Darüber hinaus liefern die Sensitivitätsstudien wichtige Hinweise für die Definition geeigneter Zielfunktionen und liefert gegebenenfalls gute Startdesigns für die Optimierung.

Für praktische Anwendungen werden möglichst robuste Einstellungen der Optimierungsstrategien und Zielfunktionen gesucht. Der Abgleich soll für wiederkehrende Aufgabenstellungen möglichst automatisiert mit Default-Einstellungen wiederholbar sein.

6 Literaturverzeichnis

- [1] D. E. Goldberg: „Evolution strategies ii: Theoretical aspects“; In Genetic Algorithms in Engineering and Computer Science, chapter 7; Wiley, Chichester, 1995
- [2] Göhler, J.: Optimierungsstrategien zur Parameteridentifikation eines viskoelastischen Materialmodells für Klebstoffe; Proceedings Weimarer Optimierung- und Stochastiktage 2.0, 2005, Weimar, Germany
- [3] Jasinski, U.: Automatisierung des Validierungsprozesses in der Insassencrashsimulation, Proceedings Weimarer Optimierung- und Stochastiktage 2.0, 2005, Weimar, Germany
- [4] H. Myers, C. Montgomery: Response Surface Methodology: Process and Product Optimization Using Designed Experiments“, Wiley, New York, 1995
- [5] OptiSLang - the Optimizing Structural Language Version 2.1, DYNARDO, Weimar, 2004, www.dynardo.de
- [6] I. Rechenberg: „Evolutionsstrategie '94“; Werkstatt Bionik und Evolutionstechnik Vol. 1; Frommann-Holzboog, Stuttgart, 1994
- [7] K. Schittkowski, C. Zillober, R. Zotemantel: “Numerical comparison of nonlinear programming algorithms for structural optimization“; Structural Optimization, Vol.7, Nr.1, S. 1-28
- [8] 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
- [9] Will, J.; Baldauf, H.: Robustheitsbewertungen bezüglich der virtuellen Auslegung passiver Fahrzeugsicherheit; Proceedings Weimarer Optimierung- und Stochastiktage 2.0, 2005, Weimar, Germany
- [10] Will, J.; Bucher, C.: Statistische Maße für rechnerische Robustheitsbewertungen CAE-gestützter Berechnungsmodelle, eingereicht bei Proceedings Weimarer Optimierung- und Stochastiktage 3.0, 2006, Weimar, Germany
- [11] V. Zabel and C. Bucher. The investigation of the dynamic behaviour of a historical bell tower. In J. M. Ko and Y. L. Xu, editors, Advances in Structural Dynamics, Vol II, pages 1101–1108. Elsevier, Amsterdam, 2000.