

Optimierungscharakteristik von endlosfaserverstärkten Kunststoffen (optimization characteristics of continuous fiber-reinforced plastics)

Markus Kellermeyer^{1,2}, Sandro Wartzack²

¹ CADFEM GmbH

² Lehrstuhl für Konstruktionstechnik, Universität Erlangen-Nürnberg

Abstract

This paper gives a short overview for the most important possibilities for parametric optimization methods in the field of numerical simulations. Subsequently criterias are listed showing the optimization characteristics of continuous fiber reinforced plastics like CFK. The evaluation of the most important optimization settings is done be an automatic process using a benchmark from industry and ensuring reliable results by performing several optimization runs. For this typical composite benchmark properties are included which make it necessary to differ from established optimization settings. With a sensitivity study and these findings the engineer can be supported to make the right decisions with regard to optimization settings in order to save time due to less runs that are necessary for his composite optimization.

Keywords: optimization, composite, best practice

1 Vorwort

Die Bandbreite an parametrischen Optimierungsalgorithmen im Bereich der Simulation ist groß. Die Entscheidung, welcher dieser Algorithmen in einer bestimmten Situation am effektivsten arbeitet ist oft von großer Bedeutung, wenn Ergebnisse für Designpunkte durch zeitintensive Simulationsrechnungen ermittelt werden müssen. Viele Möglichkeiten in Detaileinstellungen solcher Algorithmen machen die Thematik allerdings undurchsichtig, und es ist für den normalen Anwender schwierig, situationsbedingt die beste Entscheidung zu treffen.

Endlosfaserverstärkte Kunststoffe im Speziellen weisen dabei Eigenschaften auf, welche es neben weiteren allgemeinen Kriterien notwendig machen, eine individuelle Optimierungscharakteristik zu ermitteln. Anhand dieser können der vielversprechendste Optimierungsalgorithmus sowie dessen Detaileinstellungen ermittelt werden.

2 Optimierungsalgorithmen

In der Literatur ist eine Vielzahl an verschiedenen Optimierungsalgorithmen für parameterbasierte Modelle zu finden. Die Einsatzbereiche sind dabei vielfältig und stellen unterschiedliche Herausforderungen. Jede Optimierungsaufgabe besitzt also eine bestimmte Charakteristik, anhand derer der beste Optimierungsalgorithmus gewählt werden sollte, sowie dessen optimale Detaileinstellungen. Vor allem bei zeitintensiven Berechnungen, wie es bei komplexen Faserverbundberechnungen der Fall ist, ist die Wahl des richtigen Algorithmus und seinen Einstellungen ganz entscheidend. Das Ziel muss eine zuverlässig zum potentiellen Optimum konvergierende sowie zeitsparende Optimierung sein. Zweites bedeutet konkret eine Optimierung mit möglichst wenigen Rechnungen. Im Folgenden werden die Grundzüge von häufig in der Praxis verwendeten Verfahren vorgestellt, sowie deren Stärken und Schwächen benannt. In Punkt 3 werden diese Punkte auf die konkreten Aufgabenstellungen von Simulationen endlosfaserverstärkter Kunststoffe übertragen.

2.1 Evolutionärer Algorithmus

Evolutionäre Algorithmen imitieren Prozesse aus der biologischen Evolution. Verschiedene Variationen sind in der Literatur zu finden, aber ihnen allen ist meist gemeinsam, dass von Generation zu Generation eine Selektion, eine Rekombination und eine Mutation stattfinden. Häufig verwendete evolutionäre Algorithmen kombinieren genetische Algorithmen mit evolutionären Strategien, um sowohl den globalen als auch lokalen Raum nach optimalen Designs abzusuchen. Als Basis dienen dazu die Arbeiten von [1] und [2].

Um eine Startpopulation festzulegen, greifen viele Methoden auf eine zufallsbasierte Designerstellung zurück. Sehr viel effektiver gestaltet sich allerdings die Optimierung bei einer voran geschalteten Sensitivitätsstudie, in welcher eine geeignete Startpopulation manuell ermittelt werden kann.

Folgende Möglichkeiten für Detaileinstellungen in den Bereichen Population, Selektion, Rekombination und Mutation zeigen die Vielfältigkeit dieser Algorithmen, aber gleichzeitig

auch die Schwierigkeit, die richtigen Einstellungen für Faserverbundaufgaben zu bestimmen:

1. Startpopulation
 - a. Zufallsbasiertes Festlegen der Startpopulation
 - b. Manuelles Festlegen der Startpopulation
2. Selektion
 - a. Sortierung der Designs nach ihrer Fitness
 - b. Sortierung der Designs nach dem Rang ihrer Fitness
 - c. Anzahl der zu selektierenden Designs (Eltern)
 - d. Einfluss bei Verletzung von Zwangsbedingungen bei der Selektion
3. Rekombination
 - a. Jeder Parameter wird potentiell untereinander ausgetauscht. Eine vorgegebene Wahrscheinlichkeit entscheidet darüber.
 - b. Gruppenbildung von Parametern. Die Gruppen werden untereinander ausgetauscht. Der Benutzer entscheidet über die Anzahl der Gruppen.
 - c. Arithmetisch - vom Benutzer kann der Anteil zum Parametertausch festgelegt werden
4. Mutation
 - a. Mutationstyp
 - b. Mutationsrate
 - c. Standardabweichung der Verteilungskurve

Da Composite Aufgaben in den meisten Anwendungen sehr viele lokale Optima aufweisen, soll auch in den folgenden Untersuchungen ein besonderes Augenmerk auf eine globale Optimierung gelegt werden. Dabei stellt sich für den allgemeinen Anwender die Frage, mit welchen Einstellungen ein Evolutionärer Algorithmus ein befriedigendes und schnelles Ergebnis liefert. So können beispielsweise mit geringen Mutationsraten lokale Optima besser untersucht werden, bei großen hingegen potentiell noch bessere Kandidaten durch eine eher global ausgerichtete Suche erkannt werden. Den Unterschied zeigt Abbildung 1. Links wurde zu Beginn eine hohe und zum Ende hin eine geringe Streuung für die Standardabweichung der Mutation festgelegt. In der Mitte wurde sie sowohl zu Beginn als auch zum Ende hoch gesetzt und rechts beidemale eine geringe Streuung.

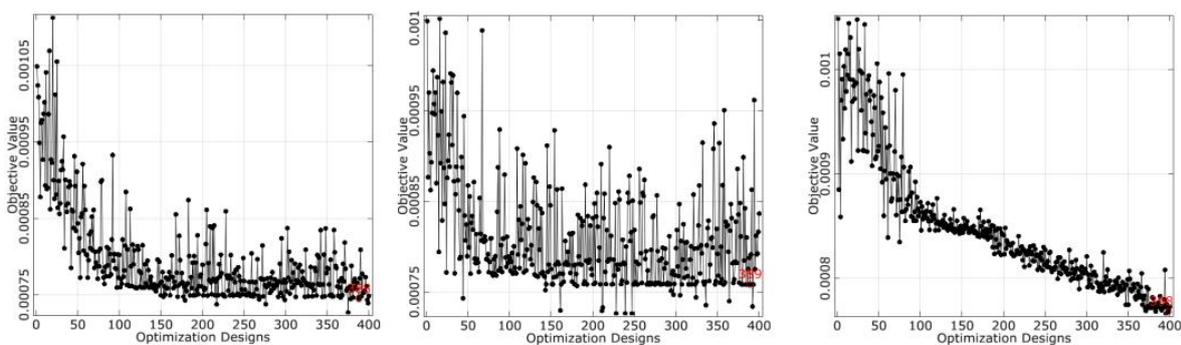


Abbildung 1: Einfluss der Mutationseinstellung auf den Optimierungsverlauf

Attraktiv ist der evolutionäre Algorithmus für Faserverbundberechnungen aus dem Grund, dass auch diskrete Parameter berücksichtigt werden können. So existieren beispielweise bei der Frage, wie viele Schichten verwendet werden sollen ihrem Wert nach sortierbare diskrete Parameter und bei der Frage, in welcher Reihenfolge Schichten angeordnet werden sollen nicht sortierbare diskrete Parameter. Zudem sind in vielen Fällen mehrere Zielfunktionen zu erfüllen, was eine Pareto Optimierung notwendig macht. Von Nachteil sind sicherlich die langsamere Konvergenz sowie das notwendige Wissen über die vielen Möglichkeiten in den Detailinstellungen.

2.2 Evolutionärer Algorithmus

Auch hier zeigen sich verschiedene Variationen, welche in [3] aufgezeigt werden. Es lässt sich allgemein sagen, dass der Particle Swarm Algorithmus das soziale Verhalten eines Schwarms imitiert. Durch einen regelmäßigen Austausch an Informationen kann der Schwarm seine Suche auf interessante Stellen konzentrieren, die ein Optimum darstellen könnten.

Auch hier wird also mit einer Population gearbeitet. Eine Weiterentwicklung wird einerseits durch das persönliche Verhalten eines jeden Individuums sowie durch das Gesamtverhalten des Schwarms beeinflusst. Dabei finden eine Selektion, eine Bewegung und eine Mutation statt. Die Selektion dient zur Ermittlung guter Positionen, in welche der Schwarm gelenkt werden kann. Sie ist in diesem Fall besonders wichtig bei Pareto-Aufgaben. Mit der Bewegung kann eine neue Suchrichtung ermittelt werden und die Mutation ist ähnlich wie bei dem evolutionären Algorithmus zu betrachten.

Folgende Variationsmöglichkeiten sollen wieder aufzeigen, dass bereits die Grundvariante des Particle Swarm Algorithmus sehr variabel einstellbar ist und damit ebenfalls auf die Optimierungscharakteristik der Aufgabe angepasst werden kann:

1. Startpopulation
 - a. Zufallsbasiertes Festlegen der Startpopulation
 - b. Manuelles Festlegen der Startpopulation
2. Selektion
 - a. Ermittlung der Fitness nach einer „strict dominance-based method“
 - b. Ermittlung der Fitness nach einer „dominance-based fitness method“
3. Bewegung
 - a. Suchstrategie
 - b. Persönlicher Anteil bei der Definition der neuen Suchrichtung (am Anfang und am Ende der Optimierung)
 - c. Persönliche Beschleunigung und Schwarmbeschleunigung bei der neuen Suche (am Anfang und am Ende der Optimierung)
5. Mutation
 - a. Mutationstyp
 - b. Mutationsrate
 - c. Standardabweichung der Verteilungskurve

Der Particle Swarm Algorithmus ist ebenfalls für diskrete Parameter geeignet und kann mit mehreren Zielfunktionen sowie Zwangsbedingungen gute Lösungen finden, was ihn für Faserverbundoptimierungen zu einer attraktiven Alternative macht. Er konzentriert sich anders als der evolutionäre Algorithmus auf eine ausgeprägte Darstellung einer möglichen Pareto Front, betreibt in der Regel die Suche nach möglichen anderen Optima jedoch nicht so intensiv wie der EA.

2.3 Gradientenbasierte Algorithmen (NLPQL)

Diese Verfahren setzen voraus, dass über den Designraum eine repräsentative Antwortfläche erstellt werden kann. Für Compositeaufgabe stellt diese Optimierung nur dann eine Lösung da, wenn diskrete Parameter nicht existent sind – wenn also beispielsweise der Lagenaufbau selbst als nicht veränderbar angesehen wird und lediglich die Faserwinkel angepasst werden sollen. Auch wenn oft diskrete Parameter als kontinuierliche Parameter betrachtet werden ist dies nicht möglich wenn nicht sortierbare diskrete Parameter vorliegen.

2.4 Adaptive Response Surface Methoden (ARSM)

Auch hier ist die Eignung dann vorhanden, wenn lediglich kontinuierliche Parameter existieren. Über einen vordefinierten Designraum wird eine ‚einfache‘ Antwortfläche gespannt, anhand welcher ein Optimum bestimmt wird, welches als neuer Startpunkt dient. Um diesen wird eine verkleinerte neue Antwortfläche generiert. Dieses Vorgehen wiederholt sich solange bis sich eine Stagnation einstellt. Die ARSM ist v.a. dann geeignet, wenn viele kontinuierliche Parameter existieren.

2.5 Stochastic Design Improvement (SDI)

Stochastic Design Improvement gilt als einfacher Algorithmus, welcher v.a. bei Aufgaben eingesetzt wird, bei denen wenig über den Designraum bekannt ist. Mit Hilfe eines Latin Hypercube Samplings (LHS) werden Designs um einen Startpunkt herum erstellt. Das Beste dieser Designs bestimmt den Startpunkt für ein erneutes LHS und lenkt somit das Optimum in eine bestimmte (lokale) Richtung. In diesen Betrachtungen ist dieses Verfahren eher ungeeignet, da eine globale Suche ein wesentlicher Erfolgsfaktor für eine Faserverbundoptimierung ist.

3 Optimierungscharakteristik von Faserverbundstrukturen

Die gezeigten Einstellungen der Algorithmen sollten in Abhängigkeit von der Optimierungscharakteristik gewählt werden. Dabei gibt es Kriterien, welche eindeutig von Anfang an festgelegt werden können (siehe [4]) sowie Kriterien die anhand von Voruntersuchungen mittels Sensitivitätsstudien ermittelt werden können. Neben Kriterien, die für allgemeine Optimierungsaufgabe angeführt werden können, lassen sich auch Kriterien für endlosfaserverstärkte Kunststoffe definieren.

3.1 Allgemeine Kriterien zur Festlegung der Optimierungscharakteristik

- Anzahl der Zielfunktionen
- Kontinuierliche und/oder diskrete Parameter
- Anzahl der (wichtigen) Eingangsparameter
- Optimierungspotential (Ermittlung in Sensitivitätsstudie)
- Höhe der Wahrscheinlichkeit für Designausfälle
- Häufigkeit der Verletzung von Zwangsbedingungen
- Numerisches Rauschen

3.2 Kriterien von endlosfaserverstärkten Kunststoffen

- Lokale Sprünge der Auswertestellen
- Wechsel der Versagensschicht
- Wechsel der Versagenskriterien
- Variationsbreite der Faserorientierungen
- Anzahl der Schichten
- Rechenzeit

4 Vergleich von Optimierungseinstellungen

Um die Qualität eines Optimierungsalgorithmus bewerten zu können, muss berücksichtigt werden, dass bei stochastisch basierten Verfahren bei jedem durchgeführtem Optimierungslauf ein anderes Ergebnis zu erwarten ist. Dabei kann das Optimum bei viel Glück schon nach wenigen Berechnungen gefunden worden sein, bei viel Pech erst nach sehr vielen. Eine Bewertung macht also nur dann Sinn, wenn die Performance über mehrere Testläufe durch den Mittelwert und seine Streuung bewertet wird. Dabei kann auf Vertrauensintervalle zurückgegriffen werden, welche z.B. eine Aussage mit einer 95%-igen Wahrscheinlichkeit liefern können, dass der tatsächliche für die Performance repräsentative Wert in einem bestimmten Intervall liegt. Bei den nachfolgenden Untersuchungen zeigte sich, dass eine Bewertung nach ca. 150 Durchläufen ein gutes Maß für einen Vergleich zwischen den Methoden und Einstellungsmöglichkeiten liefert. Abbildung 2 zeigt, wie sich bei einem evolutionären Algorithmus erst nach ca. 100 Optimierungen ein vernünftiges Vergleichsmaß für das Optimierungsziel und die dazu notwendigen Rechenläufe einstellt.

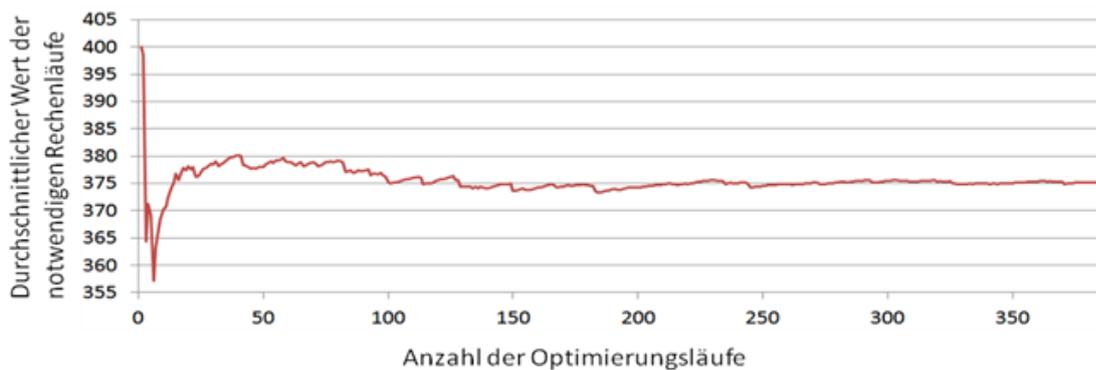


Abbildung 2: Entwicklung des Mittelwerts der notwendigen Rechenläufe

Aufgrund der daraus sich ergebenden Anzahl an notwendigen Rechnungen wurden im Vorfeld gezielt nur für interessant empfundene Algorithmen und Einstellungen gewählt.

5 Faserverbundbenchmark und Schlussfolgerungen

Verwendet wurde ein Modell aus der Praxis, welches möglichst viele unterschiedliche Charakteristiken von endlosfaserverstärkten Verbundwerkstoffen aufweist. Der Lagenaufbau wurde fertigungsgerecht und objektorientiert definiert. Nach der Definition von Materialdaten wurden Fabrics festgelegt, welche wiederum zu Stackups kombiniert wurden. Diese wurden dann zur Definition der Plies verwendet, welche zu Plygruppen zusammengefasst wurden. Diese Gruppen wurden anschließend unterschiedlichen Bereichen des Modells zugewiesen. Die Bereiche können sich dabei auch überlagern. Variabilität ist möglich in der Materialdefinition, den Fabrics, den Stackups, den Plies, den Plygroups und den Bereichen. Somit können viele der genannten Kriterien untersucht werden. Verschiebungen von verstärkenden Bereichen führen beispielsweise zu Verlagerungen im Kraftfluss und somit zu einem Sprung der Versagensstellen. Auch ein Wechsel der Versagensschicht kann in diesem Modell beobachtet werden.

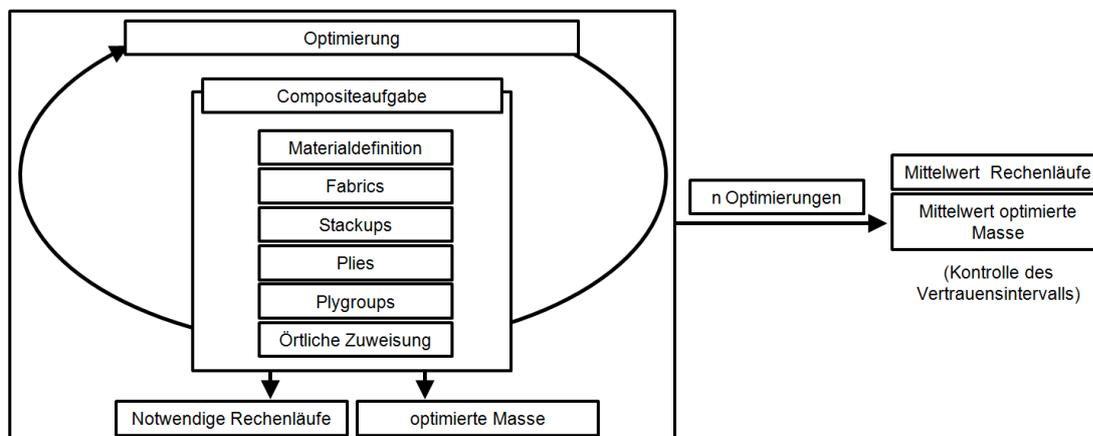


Abbildung 3: Ablauf der Optimierungsbenchmarks

Aus unterschiedlichen Algorithmen sowie deren Einstellungen bei Mutation, Population und Selektion ergeben die in Abbildung 4 dargestellten Ergebnisse:

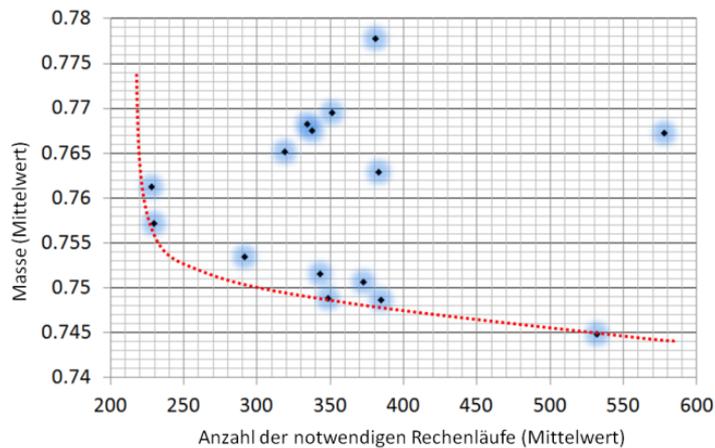


Abbildung 4: Performancebewertung der Algorithmen und Einstellungen

Daraus abgeleitet lassen sich folgende Erkenntnisse zusammenfassen:

1. Im Mittel sind evolutionäre Algorithmen zu bevorzugen (A,B)
2. Die schnellste Performance ergibt sich am ehesten bei extrem hohen Mutationsraten im EA oder einer Reduzierung der Designs pro Generation (A)
3. Die Wahrscheinlichkeit, im Schnitt eine bessere Masse zu erhalten, kann am besten durch eine Erhöhung der Designs im Archiv des EA erreicht werden (B)
4. Abzuraten ist von PSO mit hoher Populationszahl (C) aufgrund der sehr langsamen Konvergenz und der trotzdem nicht wesentlich besseren mittleren Massenreduktion im Vergleich zu EA

6 Referenzen/Literaturangaben

HOLLAND, J.H.: *Adaptation in natural and artificial systems*. University of Michigan Press, 1975

RECHENBERG, I.: *Evolutionsstrategie: Optimierung rechnerischer Systeme nach Prinzipien der biologischen Evolution*. Frommann-Holzboog, Stuttgart, 1973

COELLO, C.A. & REYES-SIERRA, M.: *Multi-objective particle swarm optimizers: A survey of the state-of-the-art*. International journal of Computational Intelligence Research, 2006

SCHNEIDER, D.; OCHESENFAHRT, D. ET AL.: *Benchmark of Nature – inspired Optimization Algorithms in fields of single and multiobjective scopes*, Weimar Optimization and Stochastic Days 7.0, 2010