

Mit genetischen Algorithmen optimierte Synthese zweidimensionaler Antennengruppen

Klaus Kark

Institut für Nachrichtentechnik der Fachhochschule Ravensburg-Weingarten
Postfach 1261, D-88241 Weingarten, e-Mail: kark@fbe.fh-weingarten.de

Zusammenfassung: Die Erkenntnisse früherer Untersuchungen [6,7] erfahren in dieser Arbeit in zweierlei Hinsicht eine Erweiterung. Die Konvergenzgeschwindigkeit des genetischen Entwicklungsprozesses wurde beträchtlich gesteigert [9,10]. Die bisherige Beschränkung auf unverkoppelte, eindimensionale Antennengruppen entfällt. Es können nun ebene Dipolgruppen unter Berücksichtigung der gegenseitigen Verkopplung behandelt werden [9]. Außerdem wurde untersucht, ob die optimierten Belegungen eine ausreichende Diagrammstabilität bei Fertigungstoleranzen aufweisen.

1. EINLEITUNG

Optimierung ist ein Vorgang, bei dem durch schrittweise Veränderung von relevanten Parametern eine Verbesserung des Ergebnisses eintritt und schließlich eine optimale Lösung gefunden wird. Es gibt Optimierungsverfahren, die schnell konvergieren aber Gefahr laufen, sich in lokale Extrema zu verirren¹. Andere² durchsuchen den Parameterraum genauer, brauchen dazu aber mehr Zeit [3].

	lokale	globale Verfahren	
	CG	RW	GA / ES / SA
globale Konvergenz	☹	☺	☺
nicht differenzierbare Zielfunktion	☹	☺	☺
Konvergenzrate	☺	☹	☹

Gleichermaßen schnelle und auch globale Konvergenz kann ein einzelnes Verfahren nicht garantieren. Das führt zur Idee von hybriden Optimierungsverfahren, bei denen die Vorteile zweier Verfahren ausgenutzt werden. In dieser Arbeit hat sich die Kombination von genetischen Algorithmen und Gradientenverfahren als günstig erwiesen. Nach einer Einführung in die Grundlagen der geneti-

schen Optimierung werden Modifikationen am Algorithmus hinsichtlich ihres die Konvergenz verbessernden Verhaltens vorgestellt. Das Hybridverfahren (GA+CG) wird schließlich zur Synthese zweidimensionaler Antennengruppen erfolgreich eingesetzt.

2. GENETISCHE ALGORITHMEN (GA)

Die ersten genetischen Algorithmen gehen auf Holland [1] zurück und wurden von Goldberg [2] populär gemacht. Seither sind eine Vielzahl von Artikeln und Lehrbüchern zur Thematik erschienen. Eine gute Übersicht findet man in [3,4,5]. Das Ziel vieler Modifikationen am ursprünglichen GA war die Verbesserung der Konvergenzgeschwindigkeit ohne jedoch seine Robustheit zu gefährden. Die Variante eines GA, welche dieser Arbeit zugrunde liegt, wurde ausführlich in [7] dargestellt und soll hier kurz erläutert werden.

2.1 Grundlagen

Die zu optimierenden Größen werden in einem Phänotypvektor zusammengefasst. Bei der Optimierung von Antennengruppen zählen dazu die Lageparameter sowie die Amplituden und Phasen der Speiseströme aller identischer Teilantennen. Ein solcher Phänotyp repräsentiert eine bestimmte physikalische Parameterkonstellation, die anschließend in einen Binärstring der Länge N_{Bit} aus Nullen und Einsen codiert wird. Dabei wird durch die Quantisierung die Auflösung des GA festgelegt. Die genetischen Operatoren Rekombination und Mutation greifen auf der Bit-Ebene direkt am sogenannten Genotyp oder Chromosom an. Mit einer Wahrscheinlichkeit p_{cross} wird eine Trennstelle gesetzt und mit p_{mutate} wird ein Bit invertiert. Der dominierende Operator eines GA ist die Rekombination. Sie bewirkt eine exponentielle Vererbung „guter“ Genketten, sogenannter Schemata oder Allele [2]. Mutationen wirken

¹ conjugated gradient (CG), Quasi-Newton, Simplex

² random walk (RW), genetic algorithms (GA), evolution strategies (ES), simulated annealing (SA)

stattdessen einer vorzeitigen Konvergenz in lokale Extrema entgegen und stellen die genetische Vielfalt und ein gründliches Durchsuchen des Parameterraums sicher.

2.2 Modifikationen

In folgender Tabelle sind alle untersuchten Varianten [9,10] unserer bisherigen Formulierung des GA [6,7] aufgelistet. Die jeweiligen Auswirkungen wurden am Beispiel der Synthese von Antennengruppen getestet. Manche führten dort zu einer Verbesserung des Konvergenzverhaltens, andere erreichten gerade das Gegenteil. Es ist nicht auszuschließen, dass manche „schlechten“ Modifikationen bei anderen Suchproblemen nicht vielleicht doch erfolgreich sein könnten.

alter GA	gute Modifikation ☺
1) generational GA	steady-state GA mit Elitismus
2) roulette wheel selection	binary tournament selection
3) Klone überleben	Klone mit random ersetzen
alter GA	schlechte Modifikation ☹
4) multi-point crossover	uniform crossover
5) eine Population	mehrere Populationsinseln
6) konstante Mutationsrate	kataklysmische Mutation

1) Im Gegensatz zum bisherigen Generationswechsel, bei dem die Nachkommen die Eltern vollständig ersetzen (100%), wird beim Steady-State-Verfahren [3] nur noch eine kleinere Anzahl von Nachkommen erzeugt, die in die Elterngeneration entsprechend ihrer Qualität einsortiert werden. Somit überlappen sich die Generationen. Dadurch

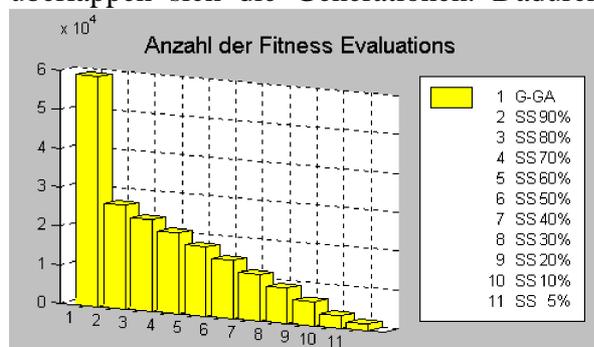


Bild 1: Verringerung der Rechenzeit durch Ausnutzung des Steady-State-Verfahrens. Die Steady-State-Rate SS gibt an, wieviel % der Generation ersetzt wird.

können einerseits neue Erbinformationen schneller am Entwicklungsprozess teilnehmen und das Überleben des besten Chromosoms ist automatisch gesichert (Elitismus).

2) Die Häufigkeit, mit der ein Individuum an Rekombinationen teilnimmt, wird bei tournament selection nicht mehr proportional seiner Fitness gewählt. Nur der Gewinner des Rankings in einer zufällig ausgewählten Subpopulation (der Größe 2) wird einem Kreuzungspartner zugewiesen [3]. Dadurch wird bis zum Ende der Optimierung ein hoher Selektionsdruck aufrecht erhalten.

3) Während der Entwicklung auftretende identische Chromosomen werden gelöscht und durch zufällige Binärstrings ersetzt [8].

4) Bei der Kreuzung zweier Chromosomen durch uniform crossover werden keine Binärketten (Allele) sondern nur einzelne Bits (Gene) ausgetauscht [4]. Die Vererbung guter Schemata wird dadurch unterbunden.

5) Die Verteilung aller Individuen auf kleinere Subpopulationen mit separatem GA in jeder Insel und Austausch der besten 20 % der Individuen nach je 5 Generationen wirkt nur bei Parallelrechnern rechenzeitverkürzend.

6) Mutationsausbrüche im Endstadium einer Entwicklung zur Erhöhung der genetischen Vielfalt haben sich als ungünstig erwiesen.

2.3 GA-Konvergenz

Ein GA hat seine Stärken in der Anfangsphase des Optimierungsprozesses. Er wird mit hoher Wahrscheinlichkeit die Umgebung des globalen Optimums finden, da er einen großen Suchraum auf geeignete Lösungen überprüft. Nach einiger Zeit konzentriert sich die Populationswolke auf ein eng begrenztes Gebiet und konvergiert dann nur noch recht langsam (**Bild 3**). Das Konvergenzverhalten eines GA soll anhand der Suche des Maximums der Funktion (**Bild 2**)

$$z(x, y) = 2 + x \sin(5 \pi x) + y \cos(5 \pi y)$$

im Bereich $0 \leq x, y \leq 1,023$ illustriert werden. Das globale Maximum (Marker •) dieses mit vielen lokalen Extrema versehenen Sinusgebirges liegt, wie man leicht nachprüft, bei $x \approx 0,9045$ und $y \approx 0,8050$.

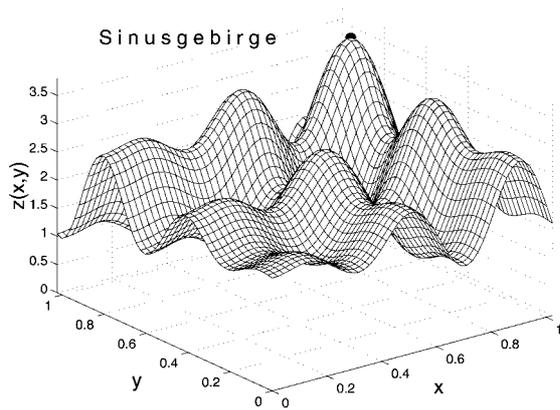
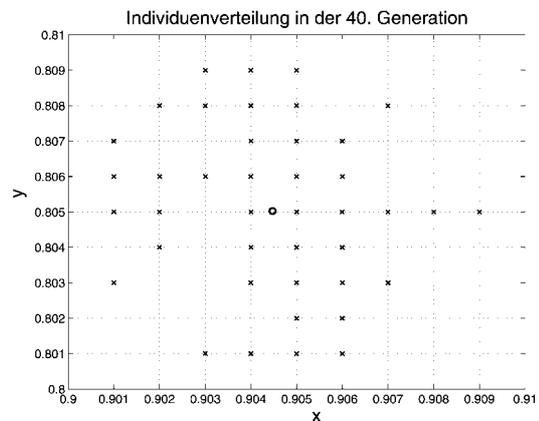
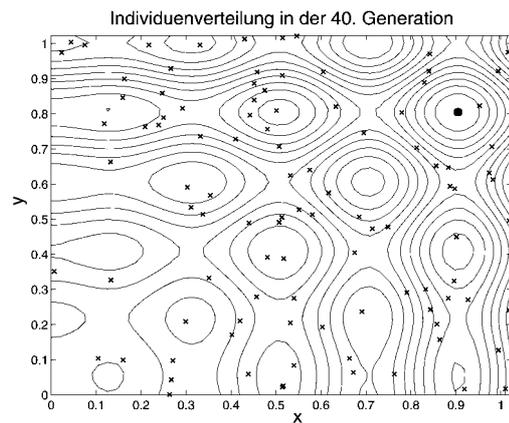
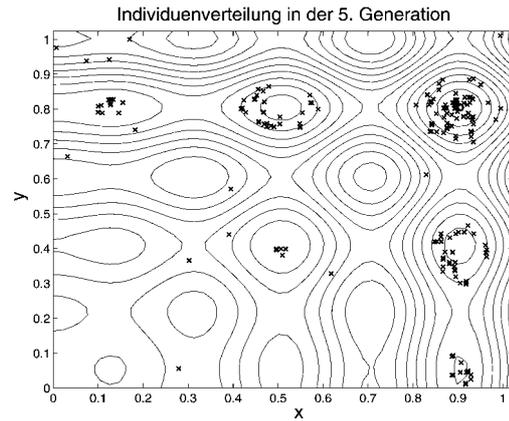
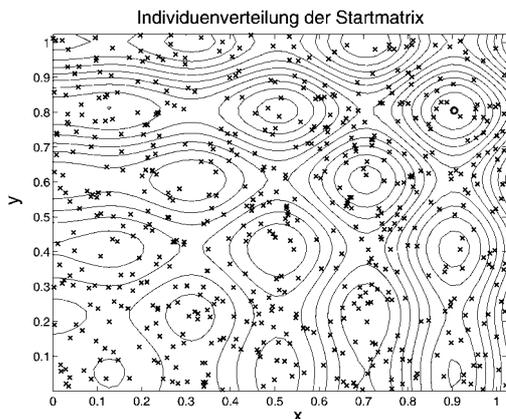


Bild 2: Sinusgebirge $z(x, y)$ als Testfunktion.

Wenn der Suchbereich in x und in y jeweils mit 10 Bit quantisiert wird, erreicht der GA eine Auflösung von $1,023/(2^{10} - 1) = 10^{-3}$. Die Aufgabe besteht nun darin, die Elemente eines unbekannt binären Strings der Länge $N_{\text{Bit}} = 20$ zu ermitteln, der die codierten x - und y -Werte des globalen Maximums repräsentiert. Insgesamt gibt es 2^{20} mögliche Anordnungen. Bei einer Population von 200 (Startpopulation 600) wird die Verteilung der Individuen zu Beginn, nach 5 und nach 40 Generationen in **Bild 3** dokumentiert.

Das Optimierungsergebnis in der Umgebung des gesuchten Maximums (Marker \bullet) ist vergrößert dargestellt. Eine genauere Annäherung an den Optimalwert ist bei der gewählten Auflösung von 10^{-3} offenbar nicht möglich. Jetzt sollte man den GA abbrechen und z.B. auf ein Gradientenverfahren überwechseln, mit dem dann sehr schnell das nächstgelegene Optimum erreicht werden kann.

Bild 3: Verteilung von 600 Phänotypen der Startpopulation und Wanderung von 200 Phänotypen (teilweise identische) in Richtung des Optimums (Marker \bullet).



2.4 Optimierte GA-Parameter

Umfangreiche Konvergenzuntersuchungen am Sinusgebirge (**Bild 2**) ergaben verbesserte Zahlenwerte für die Entwicklungsparameter. Um aussagekräftige Ergebnisse zu erhalten, wurde über jeweils 50 Versuche gemittelt. Dabei ist N_{Bit} die Länge des Genstrings.

steady state GA für 1 Population, binary tournament selection und multi-point crossover

$p_{\text{cross}} = 12\%$ $p_{\text{mutate}} = 7,5\%$ $SS = 75\%$

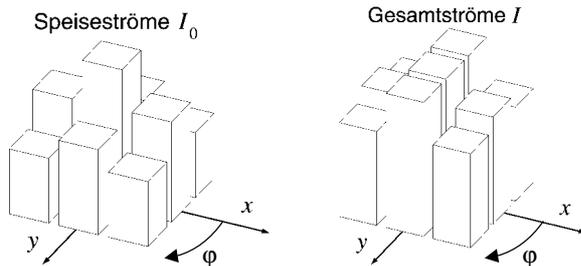
im Mittel: 2 Mutationen nach 3 Kreuzungen

Grundpopulation: 200 Startpopulation: 600

Generationen: $> 2 N_{\text{Bit}}$ Quantisierung: 12 Bit

3. GRUPPENSYNTHESE

Bild 4 zeigt das horizontale Richtdiagramm $C(\varphi, \vartheta = \pi/2)$ einer äquidistanten 3x3 Gruppe aus vertikalen Halbwellendipolen in gegenseitigem Abstand von je $0,45 \lambda$. Die Speisephasen wurden so gewählt, dass sich die Hauptstrahlung entlang der y-Achse bei $\varphi = 90^\circ$ bzw. $\varphi = 270^\circ$ einstellt.



Bei uniformer Startbelegung wurden die Stromamplituden, die über die Impedanzmatrix $[Z]$ miteinander verkoppelt sind [11]

$$(\underline{I}_0) = (\underline{I}) + [Z] / (Z_{11} + Z_L) \cdot (\underline{I}),$$

mit einem GA solange verändert bis die Abweichung von der Sollvorgabe eine vorgegebene Schranke unterschritten hatte. Die verbotenen Bereiche sind grau dargestellt.

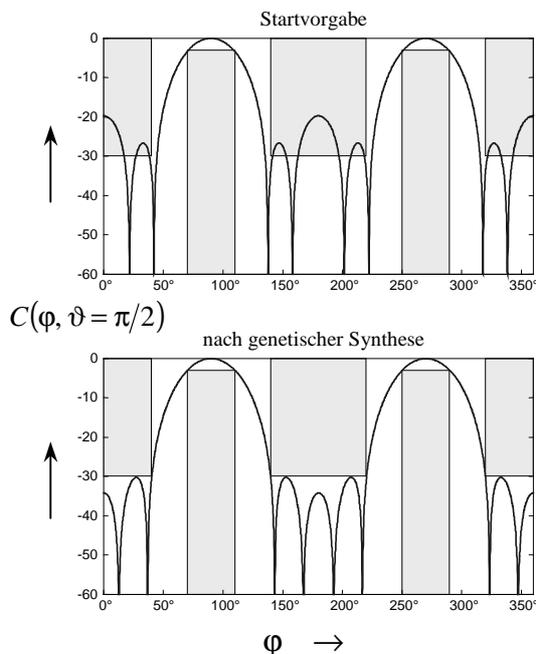


Bild 4: Horizontale Richtdiagramme einer äquidistanten 3x3 Gruppe aus vertikalen Halbwellendipolen in gegenseitigem Abstand von jeweils $0,45 \lambda$.

Übliche, normalverteilte Phasen- und Amplitudenfehler wirken sich nur gering aus.

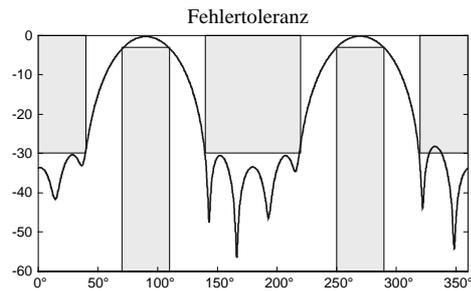


Bild 5: Optimiertes Diagramm aus **Bild 4** incl. normalverteilter Phasen- und Amplitudenfehler mit Standardabweichungen $\sigma_{\text{Phase}} = 3^\circ$ und $\sigma_{\text{Betrag}} = 0,5 \text{ dB}$.

4. SCHLUSSBEMERKUNG

Es wurde ein steady state GA mit binary tournament selection und multi-point crossover auf die Optimierung komplexer Probleme angewandt. Durch verbesserte Wahl wichtiger GA-Parameter konnte die Effizienz erheblich gesteigert werden. Neben binär codierten GA sollten künftig auch reellwertige Formulierungen untersucht werden.

- [1] **Holland, J.H.:** Adaptation in Natural and Artificial Systems. Ann Arbor: Univ. of Michigan, 1975.
- [2] **Goldberg, D.E.:** Genetic Algorithms, Reading MA: Addison-Wesley, 1989.
- [3] **Johnson, J.M.; Rahmat-Samii, Y.:** Genetic Algorithms in Engineering Electromagnetics. IEEE-AP Magazine [39] 4, August 1997, 7-25.
- [4] **Haupt, R.L.; Haupt, S.E.:** Practical Genetic Algorithms. New York: John Wiley, 1998.
- [5] **Rahmat-Samii, Y.; Michielssen, E.:** Electromagnetic Optimization by Genetic Algorithms. New York: John Wiley, 1999.
- [6] **Schönenberger, H.:** Optimierung von Antennen-Gruppenstrahlern mit Hilfe von genetischen Algorithmen. Diplomarbeit, FH Ravensburg-Weingarten, 1997.
- [7] **Schönenberger, H.; Kark, K.W.:** Optimierung von Gruppenantennen mit Hilfe von genetischen Algorithmen. ITG-Fachtagung „Antennen 1998“, ITG-Fachbericht Nr. 149, 135-140.
- [8] **Weh, S.:** Optimierung Digitaler Filter mit genetischen Algorithmen. Diplomarbeit, Uni-GH Siegen, 1998.
- [9] **Sassano, M.:** Antennensynthese mit genetischen Algorithmen. Diplomarbeit, FH Ravensburg-Weingarten, 1999.
- [10] **Kneissle, J.:** Optimierung von Hohlleiterschaltungen mit genetischen Algorithmen. Diplomarbeit, FH Ravensburg-Weingarten, 1999.
- [11] **Lo, Y.T.; Lee, S.W.:** Antenna Handbook. New York: Van Nostrand Reinhold, 1988.