

論文 / 著書情報
Article / Book Information

題目(和文)	広帯域な光学・電磁波多層媒質の設計に関する研究
Title(English)	
著者(和文)	百瀬智也
Author(English)	Tomoya Momose
出典(和文)	学位:博士(工学), 学位授与機関:東京科学大学, 報告番号:甲第276号, 授与年月日:2025年3月26日, 学位の種別:課程博士, 審査員:梶川 浩太郎,伊藤 治彦,宮本 智之,雨宮 智宏,當麻 真奈,岩見 健太郎
Citation(English)	Degree:Doctor (Engineering), Conferring organization: Institute of Science Tokyo, Report number:甲第276号, Conferred date:2025/3/26, Degree Type:Course doctor, Examiner:,,,,,
学位種別(和文)	博士論文
Type(English)	Doctoral Thesis

博士論文

広帯域な光学・電磁波多層媒質の設計に関する研究

百瀬 智也



2025 年 2 月

東京科学大学 大学院工学院
電気電子系 電気電子コース

本論文は東京科学大学大学院工学院に
博士 (工学) 授与の要件として提出した博士論文である。

広帯域な光学・電磁波多層媒質の設計に関する研究*

百瀬 智也

概要

本論文では、遺伝的アルゴリズムを用いて広帯域な光学・電磁波多層媒質を設計した。具体的には、広帯域な光学クロッキング媒質と自動車レーダー向けミリ波吸収体を設計した。光学クロック設計では、直径 $1\mu\text{m}$ の円筒形対象物体を総厚さ $0.5\mu\text{m}$ の多層円筒クロックで覆った構造を検討した。インピーダンス整合を考慮し、クロック対象物周囲の誘電率分布を設計することで、線形座標変換の理論を用いた解析解と比較して 10 倍の不可視化性能を実現した。一方、ミリ波吸収体設計では、グラファイト/PDMS 複合材料を用いた 10 層構造（総厚さ 0.5 mm ）のグラファイト含有率を設計し、W バンド全域で 20 dB 以上の高吸収率を達成した。また、吸収性能を維持しながら、グラファイト含有率の低減および層数を削減することで、大量生産に適した吸収体を実現した。本研究は、「薄さ」と「広帯域」を両立する多層媒質の新たな設計指針を示し、次世代の高性能な光学デバイスや自動車レーダー吸収体の開発に貢献する。

キーワード: 多層媒質, 光学クロック, ミリ波吸収体, 遺伝的アルゴリズム

* 東京科学大学 大学院工学院 電気電子系 電気電子コース 博士論文, 2025 年 2 月 26 日.

A Study on the Design of Broadband Optical and Electromagnetic Multilayer Media[†]

Tomoya Momose

Abstract

This doctoral thesis presents the design of broadband optical and electromagnetic multilayer media using a genetic algorithm. Specifically, broadband optical cloaks and millimeter-wave absorbers for automotive radar applications were investigated. In the design of an optical cloak, a cylindrical object with a diameter of $1\mu\text{m}$ was covered with a multilayer cylindrical cloak with a total thickness of $0.5\mu\text{m}$. By designing the permittivity distribution around the cloaked object considering impedance matching, an invisibility performance ten times higher than the theoretical prediction derived using the linear coordinate transformation was achieved. In the design of the millimeter-wave absorber, a 10-layer graphite/PDMS composite materials (total thickness : 0.5 mm) was optimized to determine graphite contents, achieving high absorptance exceeding 20 dB across the entire W-band. Additionally, absorbers suitable for mass production were realized by reducing the graphite content and the number of layers while maintaining high absorption performance. This study proposes a novel design approach for multilayer media that simultaneously satisfies “thinness” and “broadband” characteristics. This will contribute to the advancement and practical implementation of next-generation optical devices and automotive radar absorbers.

Keywords: Multilayer media, optical cloak, millimeter-wave absorber, genetic algorithm

[†] Doctoral Thesis, Department of Electrical and Electronic Engineering, School of Engineering, Institute of Science Tokyo, February 26, 2025.

目次

第 1 章	序論	1
1.1	光学・電磁波多層媒質の概要	1
1.2	本論文の目的	1
1.3	光学・電磁波多層媒質の設計における確率を含む最適化アルゴリズム	2
1.3.1	ディープラーニング (DL)	3
1.3.2	ベイズ最適化 (BO)	10
1.3.3	遺伝的アルゴリズム (GA)	14
第 2 章	遺伝的アルゴリズムの有効性	19
2.1	各手法の計算条件	19
2.2	未知パラメータが 4 個の場合	21
2.3	未知パラメータが 6 個の場合	25
2.4	未知パラメータが 8 個の場合	28
2.5	未知パラメータが 16 個の場合	31
2.6	結論	34
第 3 章	広帯域な光学クロークの設計	35
3.1	概要	35
3.2	序論	35
3.3	Mie 散乱理論 / 転送行列法	36
3.3.1	波動方程式	36
3.3.2	境界条件	38
3.3.3	多層円筒構造の散乱	38
3.4	設計方法	41
3.5	結果	44
3.6	考察	50
3.7	結論	51
第 4 章	ミリ波吸収体の設計	53

4.1	概要	53
4.2	序論	53
4.3	フレネル方程式 / 転送行列法	54
4.3.1	透過と反射 (界面)	54
4.3.2	透過と反射 (多層問題)	56
4.4	設計方法	58
4.5	結果と考察	59
4.5.1	吸収スペクトル	59
4.5.2	AGA で設計された狭帯域 MLA の簡略化	63
4.5.3	AGA で設計された広帯域 MLA の簡略化	64
4.6	結論	66
第 5 章	結論	69
	謝辞	71
	参考文献	73
付 録 A	遺伝的アルゴリズムの有効性	83
A.1	BO を用いた NN のハイパーパラメータ最適化	83
A.1.1	概要	83
A.1.2	NN 構築のためのデータセット作成	83
A.1.3	ベイズ最適化の実行	84
A.2	未知パラメータが 4 個の場合	90
A.3	未知パラメータが 6 個の場合	92
A.4	未知パラメータが 8 個の場合	94
A.5	未知パラメータが 16 個の場合	96
付 録 B	広帯域な光学クロークの設計	99
B.1	Model II の設計結果	99
B.2	対象物体の比誘電率を変えた場合のクロッキング指数	102
B.3	Model I における 8 層, 12 層, 16 層, 20 層, 32 層 CM の異方性誘電率	102
付 録 C	ミリ波吸収体の設計	105
C.1	試料の作製方法・比誘電率の測定方法と測定データ	105
C.2	異なる適合度関数で設計した MLA	105
C.3	MLA の簡略化	108
C.3.1	狭帯域 MLA	108
C.3.2	広帯域 MLA	109

C.4	簡略化した MLA の入射角度依存性	109
付 録 D	研究業績	113

目 次

1.1	ニューラルネットワーク (NN) の位置づけ	4
1.2	活性化関数 $h()$ を明示したネットワーク	5
1.3	ReLU, SoftPlus, Sigmoid, Tanh および Softsign のグラフ	7
1.4	Softmax のグラフ	7
1.5	UCB, LCB の標準偏差 σ の係数の遷移	13
1.6	遺伝的アルゴリズムの概略	15
1.7	一点交叉の概略	17
1.8	二点交叉の概略	17
1.9	一様交叉の概略	17
1.10	式 (1.37), (1.38) に基づく適合度値 FV と交叉確率および突然変異確率の関係	18
2.1	8 層円筒構造の概略図	21
2.2	未知パラメータが 4 個の場合の累積計算時間 (hour) における各最適化手法の 平均散乱断面積	23
2.3	未知パラメータが 4 個の場合の異なる最適化手法における平均散乱断面積の 比較を示した箱ひげ図	23
2.4	未知パラメータが 4 個の場合の異なる最適化手法における散乱断面積スペク トル	24
2.5	未知パラメータが 6 個の場合の累積計算時間 (hour) における各最適化手法の 平均散乱断面積	26
2.6	未知パラメータが 6 個の場合の異なる最適化手法における平均散乱断面積の 比較を示した箱ひげ図	27
2.7	未知パラメータが 6 個の場合の異なる最適化手法における散乱断面積スペク トル	27
2.8	未知パラメータが 8 個の場合の累積計算時間 (hour) における各最適化手法の 平均散乱断面積	29
2.9	未知パラメータが 8 個の場合の異なる最適化手法における平均散乱断面積の 比較を示した箱ひげ図	29

2.10	未知パラメータが 8 個の場合の異なる最適化手法における散乱断面積スペクトル	30
2.11	未知パラメータが 16 個の場合の累積計算時間 (hour) における各最適化手法の平均散乱断面積	32
2.12	未知パラメータが 16 個の場合の異なる最適化手法における平均散乱断面積の比較を示した箱ひげ図	33
2.13	未知パラメータが 16 個の場合の異なる最適化手法における散乱断面積スペクトル	33
3.1	座標変換クローク	36
3.2	円筒クロークの形状	42
3.3	有効媒質近似	42
3.4	8 層 CM の設計結果	44
3.5	AGA で設計した 8, 12, 26 層 CM の SCS スペクトル	45
3.6	各 CM の ε_A および ε_B	46
3.7	各 CM の層数に対するクロッキング指数の変化	47
3.8	クロッキング指数の箱ひげ図	48
3.9	磁場の y 方向成分 (H_y) のスナップショット	49
3.10	AGA で設計された 26 層 CM の ε_r および ε_θ	50
3.11	AGA で設計した 26 層クロークのインピーダンスプロファイル	52
4.1	N 層の多層媒質	57
4.2	多層吸収体の概略図	58
4.3	総厚さ D が 0.1–0.5 mm の吸収体における吸収スペクトル	60
4.4	異なる総厚さ D の MLA におけるグラファイト含有率プロファイル (15% 制約下)	61
4.5	異なる総厚さ D の MLA におけるグラファイト含有率プロファイル (10% 制約下)	62
4.6	(a) 狭帯域 MLA ($D = 0.3$ mm) および (b) 広帯域 MLA ($D = 0.5$ mm) における正規化された電場分布	63
4.7	吸収体の総厚さ $D = 0.3$ mm における元の設計と簡略化された構造による吸収スペクトルの比較 (15% 制約下で設計)	64
4.8	吸収体の総厚さ $D = 0.5$ mm における元の設計と簡略化された構造による吸収スペクトルの比較 (15% 制約下で設計)	66
A.1	NN の構造	85
A.2	early stopping 採用時の各 RMSE の推移	86
A.3	early stopping なしの各 RMSE	87

A.4	テスト RMSE のヒストグラム	87
A.5	最良予測	88
A.6	最悪予測	89
A.7	平均予測	89
A.8	未知パラメータが 4 個の AGA における進化過程	90
A.9	未知パラメータが 4 個の GA における進化過程	90
A.10	未知パラメータが 4 個の NN+AGA における進化過程	91
A.11	未知パラメータが 4 個の BO における最適化過程	91
A.12	未知パラメータが 6 個の AGA における進化過程	92
A.13	未知パラメータが 6 個の GA における進化過程	92
A.14	未知パラメータが 6 個の BO における最適化過程	93
A.15	未知パラメータが 8 個の AGA における進化過程	94
A.16	未知パラメータが 8 個の GA における進化過程	94
A.17	未知パラメータが 8 個の BO における最適化過程	95
A.18	未知パラメータが 16 個の AGA における進化過程	96
A.19	未知パラメータが 16 個の GA における進化過程	96
A.20	未知パラメータが 16 個の BO における最適化過程	97
B.1	Model I と Model II の 26 層および 32 層 CM の SCS スペクトル (C_{sca})	99
B.2	Model II ($\varepsilon_A^i > \varepsilon_B^i$) の (a) ε_A および (b) ε_B	100
B.3	Model II ($\varepsilon_A^i > \varepsilon_B^i$) におけるクローキング指数	101
B.4	Model II の 26 層または 32 層 CM における ε_r および ε_θ	101
B.5	異なる比誘電率 ε_T を持つ対象物体に対するクローキング指数	102
B.6	Model I における 8 層, 12 層, 16 層, 20 層, 32 層 CM に対して AGA で設計 された ε_r および ε_θ	103
C.1	各材料の比誘電率スペクトル	106
C.2	簡略化した狭帯域 MLA の吸収率に関する等高線プロットと吸収率スペクトル	108
C.3	簡略化した広帯域 MLA の吸収率に関する等高線プロットと吸収率スペクトル	109
C.4	簡略化した狭帯域 MLA の s-偏光における入射角度依存性	110
C.5	簡略化した狭帯域 MLA の p-偏光における入射角度依存性	111
C.6	簡略化した広帯域 MLA の s-偏光における入射角度依存性	111
C.7	簡略化した広帯域 MLA の p-偏光における入射角度依存性	112

表 目 次

4.1	ARF バンド向け吸収体の性能比較	65
4.2	広帯域吸収体の性能比較	66
A.1	early stopping 採用時の各 RMSE	85
A.2	early stopping 採用時の最適化されたハイパーパラメータ	86
A.3	1000 エポック終了時の各 RMSE	87
A.4	各 MAPE	88
C.1	異なる適合度関数を使用して設計された MLA の吸収率スペクトル	107
C.2	広帯域吸収体の許容入射角度の比較	112

第 1 章

序論

1.1 光学・電磁波多層媒質の概要

光学分野や電波分野において、多層媒質で構成される材料が開発されている。光学分野では、誘電率の異なる 2 種類の誘電体を交互に積み重ねた多層膜構造は、特定の波長での反射や透過を制御できる多層膜干渉フィルタとして知られ、古くから使われてきた。一次元 Bragg 反射鏡は、波長の $1/4$ の厚さごとに屈折率が異なる層を積み重ねた多層膜構造で構成されている。この構造の反射率や透過率は、多層膜を構成する材料の屈折率差や吸収、層数などで決まる。屈折率差が大きいほど少ない層数で高い反射率が得られ、層数が大きいほど急峻なフィルタ特性が得られる。

電波分野では、電波吸収体として Salisbury screen [1] や Dallenbach layer が知られている。Salisbury screen は、反射板として機能する金属基板、吸収波長の $1/4$ 厚さの無損失誘電体層、そして空気に接する薄い吸収層の 3 層で構成されている。この構造も干渉を利用しており、光学分野の反射防止膜と同様の手法で設計可能であるが、吸収バンド幅が狭い。そのため、近年は様々なメタマテリアルを用いた広帯域な吸収体が提案されている [2, 3]。また、電波の波長の $1/4$ 厚さを必要とするため、薄くできないという問題点もある。

従来、多層媒質の最適設計には数値計画法が用いられてきた。この手法を用いるためには、(1) 目的関数が数式で明示的に記述されている；(2) 微分可能である；(3) 計算コストが低いなどの要件がある [4]。しかし、現実の最適設計問題ではブラックボックス関数を扱うことが多い。この場合においても、計算コストが低ければ、数値的に微分などを計算することができるため、この手法を用いることができる。しかし、目的関数が複数の谷を持つ場合、効率の良い探索を行うことができない。そこで代替手法として、確率を伴う最適化アルゴリズムが検討されてきた。

1.2 本論文の目的

本研究の目的は、確率を伴う最適化アルゴリズム、特に遺伝的アルゴリズム (GA) を用いた高性能な多層媒質の設計手法を検討することである。具体的には、多層円筒で構成される光学

クロッキング媒質およびミリ波多層吸収体を設計対象とし、それぞれの設計パラメータ（各層の比誘電率やグラファイト含有率）を最適化することで、広帯域で高性能な媒質を実現することを目指した。

1.3 光学・電磁波多層媒質の設計における確率を含む最適化アルゴリズム

多層媒質の設計における確率を含む最適化アルゴリズムの活用について検討を行った。これらの手法は、目的関数がブラックボックスかつ多峰性関数に対して、現実的な計算時間内で合理的な解を得るために有用であることが知られている [4-6]。

単純な手法としてランダム探索が挙げられるが、この方法は計算時間が長く、効率的でない。強化学習 (RL) は、試行錯誤を繰り返しながら最適な方策を学習する手法として知られている [7]。また、非線形回帰やガウス過程回帰といった代理モデルを活用することで、計算負荷の高い関数やシミュレーション結果を近似することが可能である。このアプローチに基づき、ディープラーニング (DL) [8] を用いた網羅的な計算や、ベイズ最適化 (BO) を利用した効率的な探索が実現できる [9-11]。一方、目的関数の明示的な数式化を必要とせず、出力の評価値だけを利用するメタヒューリスティクスも選択肢の一つである。例として、鳥の群れや魚の群れが集団としてエサを探す行動に着想を得た粒子群最適化 (PSO) [12, 13] や、生物の進化における自然選択と遺伝のメカニズムを模倣した GA [14] などがある。

DL は、一般的には、複雑なデータパターンを学習し、分類や回帰といった予測問題に使用されるが、解析計算プログラムを学習済みのニューラルネットワーク (NN) モデルに置き換えることで、最適化問題を高速に解くこともできる。先行研究では、8 層同心円筒光学クロックの高速設計 [15] や多層ナノ粒子を用いたナノフォトニック逆設計問題 [16] に DL が活用されている。しかし、この手法は大量の学習データを必要とし、解の探索範囲が学習データ内に限定されるという課題を抱えている。

それに対して、RL は大量の学習データを用意する必要がなく、DL の学習データの範囲を超えて新しい解を見つけることが可能である。この手法は、通常、ロボット制御やゲームなどの動的環境におけるエージェントの行動最適化に用いられる手法であるが、微細構造の幾何学的パラメータを状態変化に基づいて最適化する目的でも利用可能である。先行研究では、deep Q-learning を用いて誘電体ナノ構造の形状最適化を行い、従来よりも純度の高い RGB カラーを生成することに成功し、この手法が複雑な光学設計問題を効率的に解決する可能性を示した [17]。しかし、計算コストが高いため、1 つの解を得るまでに多大な時間を要する。

BO も大量の学習データが不要で、効率的な解探索が可能である。さらに並列処理に対応しているため、設計時間を短縮できる。先行研究では、BO を活用して超狭帯域な波長選択型熱放射体を設計し、実際に作製された試料は従来を上回る性能を達成し、BO によるメタマテリアル設計の可能性を示した [18]。しかし、低次元の入力データに対しては有効であるものの、高次元データでは適用が困難となる場合があり、局所解に陥るリスクがある。

以上の課題を踏まえ、現実的な時間で合理的な解を得たい場合には、(1) 学習データの用意が不要で、(2) 並列処理が可能で、(3) 高次元問題に対応可能で、(4) 大域的最適解を導き出せる手法が必要である。これらの要件を満たす手法が GA である。先行研究では、GA を用いた最適化により、非磁性等方性材料を最小限の層数で構成する多層円筒クロックを設計し、従来より簡素で実現可能な構造と優れた性能を実現した [19]。また、GA を用いて誘電体のみで構成された多層構造の材料と厚みを最適化し、通信波長で散乱を 80 倍抑制することで、効果的なクロックを実現した [20]。

GA が適用しやすいオプティクスと、PSO や BO が適用しやすいオプティクスについて説明する。まず、GA が適しているのは、多層構造の誘電率や厚さの最適化が求められる問題である。例えば、26 層同心円筒構造を設計する場合、マクスウェル方程式から厳密解を求められる。このような問題では、1 つの構造の散乱断面積を算出するのに約 2 秒かかり、評価する構造数が 60 万の場合、全体の計算時間としては 2 週間程度を要する。一方で、PSO や BO が適しているのは、メタサーフェスの幾何学的形状の最適化が求められる場合である。具体例として、ビームデフレクタ [21] や矩形アンテナ [22] の形状最適化が挙げられる。これらの設計では、有限差分時間領域法や有限要素法などのシミュレーション手法を用いるため、1 つの構造を評価するために多大な時間を要する。1 評価につき 10 分かかると仮定すると、評価する構造数が 3000 の場合、総計算時間は 3 週間程度となる。このように、GA は厳密解を導ける比較的単純な構造の材料パラメータの最適化に適しており、PSO や BO は代数的または解析的に解けない複雑な形状の最適化に適用される。

以下のサブセクションにおいて、各手法のアルゴリズムの詳細を説明する。

1.3.1 ディープラーニング (DL)

NN または DL とは、生物の神経回路網の構造や応答原理を模倣し、脳の情報処理をモデル化した人工的な計算システムである [8]。この概念は、Rosenblatt によるパーセプトロンの提案に端を発している [23]。NN は機械学習の一手法である。機械学習とは、人工知能の一種でデータの中に内包される隠れたルールや法則をコンピュータが学習する手法の総称である。NN、機械学習、人工知能は図 1.1 のように位置づけられる。

NN の学習手順について概要を説明する。

1. NN の重みパラメータ $\mathbf{W}$ の初期値をランダムに設定する。
2. NN に対し、学習データを用いて順方向計算を実行し、損失関数 L の値を計算する。
3. 誤差逆伝播法を実行する。この手法は、合成関数の微分公式を利用することによって、 $\mathbf{W}$ における損失勾配 $\frac{\partial L}{\partial \mathbf{W}}$ を求めるものである。
4. $\frac{\partial L}{\partial \mathbf{W}}$ をオプティマイザの更新式に代入することによって、 L の値をより小さくするような $\mathbf{W}$ を求める。
5. 手順 2 に戻る。事前に設定したエポック数や Early stopping などが終了条件を満たしたら学習を終了する。




図 1.1 ニューラルネットワーク (NN) の位置づけ

以上の処理を行うことで損失関数 L の値を最小にする最適パラメータ $\mathbf{W}$ が得られる。

ハイパーパラメータとは、機械学習アルゴリズムの挙動を設定するパラメータのことである。NN のハイパーパラメータには隠れ層の数 H 、各隠れ層のノード数 N 、活性化関数、オプティマイザ、バッチサイズ、エポック数などがある。隠れ層の数 H 、各隠れ層のノード数 N は、例えば図 1.1 の NN では $H = 3$ 、 $N = 4$ である。DL は NN を基盤としており、隠れ層を増やした進化形のことを指す。

以下では、活性化関数、オプティマイザ、バッチサイズ、エポック数について説明する。

・ 活性化関数


活性化関数とは、入力信号の総和を出力信号に変換する関数のことである。活性化関数 $h()$ を明示したネットワークを図 1.2 に示す [24]。図 1.2 では、式 (1.1) のように重み付き入力信号 w_1x_1, w_2x_2 とバイアス b の総和 a を求めている。そして、式 (1.2) のように入力信号の総和 a が活性化関数 $h()$ によって変換され、 y が出力される。NN に非線形性を持たせるためには活性化関数が必要である。ここでは、活性化関数として「ReLU」, 「Sigmoid」, 「tanh」, 「Softmax」, 「Softsign」, 「SoftPlus」について説明する。各関数およびそれらを微分した関数のグラフを図 1.3 および 1.4 に示す。

$$a = b + w_1x_1 + w_2x_2 \quad (1.1)$$

$$y = h(a) \quad (1.2)$$

＊ ReLU

単純な数式で表され、高速な演算が可能である。入力値が負の場合には出力は常にゼロであり、正の場合は入力をそのまま出力する。順伝播は式 (1.3)、逆伝播は式 (1.4) で表される。 $x = 0$ で微分不可能であるが、重みの値がちょうどゼロになるこ

図 1.2 活性化関数 $h()$ を明示したネットワーク

とは稀なため、問題にならない。

$$y = \begin{cases} x & (x > 0), \\ 0 & (x \leq 0) \end{cases} \quad (1.3)$$

$$\frac{\partial y}{\partial x} = \begin{cases} 1 & (x > 0), \\ 0 & (x \leq 0) \end{cases} \quad (1.4)$$

* Sigmoid

二値分類問題の出力層に使われることが多い。なぜなら、この関数はすべての値を 0 から 1 の間の値に変換し、確率を出力することに適しているためである。順伝播は式 (1.5)、逆伝播は式 (1.6) で表される。極端に大きい値や小さい値の入力で微分するとほとんどゼロになってしまうこと、微分値が最大でも 0.25 であることから、層数が多い NN では勾配消失問題が発生してしまう。

$$y = \frac{1}{1 + e^{-x}} \quad (1.5)$$

$$\frac{\partial y}{\partial x} = y(1 - y) \quad (1.6)$$

* tanh

順伝播は式 (1.7)、逆伝播は式 (1.8) で表される。微分の最大値が 1 であり、Sigmoid 関数で問題となった勾配消失の原因の一つが解消されている。

$$y = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (1.7)$$

$$\frac{\partial y}{\partial x} = \frac{4}{(e^x + e^{-x})^2} \quad (1.8)$$

* Softmax

値のベクトルを確率分布に変換する関数である。順伝播は式 (1.9)、逆伝播は式 (1.10) で表される。ここで、 n は出力層のノード数であり、 δ_{ij} はディラックのデルタ関数である。主に多値分類問題の出力層の活性化関数として使われる。出力値の

総和が 1 に正規化され, それぞれの出力は 0 から 1 の値を取るため, 多値分類の確率を表現することができる.

$$y_i = \frac{e^{x_i}}{\sum_{k=1}^n e^{x_k}} \quad (i = 1, 2, \dots, n) \quad (1.9)$$

$$\left(\frac{\partial y}{\partial x}\right)_i = \sum_{j=1}^n y_i(\delta_{ij} - y_j) \quad (1.10)$$

* Softsign

性質が $\tanh$ に似ている. 極端に大きい値や小さい値の入力に対する微分がゼロになってしまう問題が少し改善されている. 順伝播は式 (1.11), 逆伝播は式 (1.12) で表される.

$$y = \frac{x}{1 + |x|} \quad (1.11)$$

$$\frac{\partial y}{\partial x} = \frac{1}{(1 + |x|)^2} \quad (1.12)$$

* SoftPlus

性質が ReLU に似ている. 順伝播は式 (1.13), 逆伝播は式 (1.14) で表される. ReLU とは違って, 全ての点で微分可能になっており, ゼロ以下の入力に対しても反応するように設計されている.

$$y = \ln(1 + e^x) \quad (1.13)$$

$$\frac{\partial y}{\partial x} = \frac{1}{1 + e^{-x}} \quad (1.14)$$




図 1.3 各活性化関数のグラフ. (a) ReLU および SoftPlus, (b) ReLU および SoftPlus の微分, (c) Sigmoid, Tanh および Softsign, (d) Sigmoid, Tanh および Softsign の微分のグラフ.




図 1.4 Softmax のグラフ. (a) 2つの入力 (x_1, x_2) に対する Softmax の出力. 出力値の総和は1になっている. (b) ヤコビ行列の対角成分 (自己微分成分) のプロット. $n = 2$ の場合は, 図 1.3(d) の Sigmoid の微分と一致する.

・ オプティマイザ [24]

NN の学習の目的は、損失関数の値をできるだけ小さくする重みパラメータを見つけることである。ニューラルネットワークのパラメータ空間は非常に大きく、複雑なため、解析的に最適化問題を解くことができない。そこで、最適な重みパラメータを見つけるために、重みパラメータの勾配を手がかりにする。パラメータの勾配を用いて、勾配方向にパラメータを更新するというステップを何度も繰り返して、徐々に最適なパラメータへと近づけていくことをおこなう。これを確率的勾配降下法 (SGD) といい、以下ではオプティマイザとして、「SGD」, 「Momentum」, 「Adagrad」, 「RMSProp」, 「Adam」, 「Adamax」, 「Nadam」, 「Adadelta」の説明をする。

＊ SGD

他の多くのオプティマイザは、この SGD をベースとしている。SGD の重みパラメータ更新の式 (1.15) を示す。重みパラメータを $\mathbf{W}$ とすると、 $\frac{\partial L}{\partial \mathbf{W}}$ は、 $\mathbf{W}$ に関する損失関数 L の勾配である。 η は学習率であり、デフォルトでは 0.01 程度の値が使われる。式から分かるように、SGD は勾配方向へある一定距離だけ進む方法である。欠点は、関数の形状が等方的でないと非効率な経路で探索することになる。これは、勾配の方向と最小値が存在する位置への方向とが一致していないことに起因する。

$$\mathbf{W} \leftarrow \mathbf{W} - \eta \frac{\partial L}{\partial \mathbf{W}} \quad (1.15)$$

＊ Momentum

Momentum は以下の式 (1.16), (1.17) で示される。 $\mathbf{v}$ は物理でいうところの「速度」に対応する。式 (1.16) では、物体が勾配方向に力を受け、その力によって物体の速度が加算されるということを表している。また、勾配がないとき (第二項がゼロ) は徐々に減速するように α の値を 0.9 等に設定しておく。このように更新式を設定することで、直前だけでなく今までの勾配情報が保持されるため、異方的な形状の損失関数に対して効果的に重みパラメータの更新ができる。何度も更新する際に、常に同じ傾きを持っている方向へは速度が上がり、正と負の力を交互に受ける方向へは速度が落ちる。

$$\mathbf{v} \leftarrow \alpha \mathbf{v} - \eta \frac{\partial L}{\partial \mathbf{W}} \quad (1.16)$$

$$\mathbf{W} \leftarrow \mathbf{W} + \mathbf{v} \quad (1.17)$$

＊ Adagrad

各パラメータの学習率を別々に調整する手法である。式 (1.18) より、 $\mathbf{h}$ はこれまでの勾配を二乗和として保持する。 $\odot$ は行列の要素ごとの掛け算を意味する。そして、式 (1.19) より、 $\mathbf{W}$ 更新時に $\frac{1}{\sqrt{\mathbf{h}}}$ をかけることで学習率を調整している。これは、パ

ラメータの中で大きく更新された要素は、学習率が小さくなることを意味する。

$$\mathbf{h} \leftarrow \mathbf{h} + \frac{\partial L}{\partial \mathbf{W}} \odot \frac{\partial L}{\partial \mathbf{W}} \quad (1.18)$$

$$\mathbf{W} \leftarrow \mathbf{W} - \eta \frac{1}{\sqrt{\mathbf{h}}} \frac{\partial L}{\partial \mathbf{W}} \quad (1.19)$$

* RMSProp

これまでの勾配を二乗和として全て保持するため、無限に学習を行ったとすると更新量がゼロになってしまうという、AdaGrad の問題を解消した手法である。RMSProp は、過去のすべての勾配を均一に加算していくのではなく、過去の勾配を徐々に忘れて、新しい勾配の情報が大きく反映されるように加算する。

* Adam Adam は、勾配を移動平均して振動を抑制する「Momentum」とパラメータの要素ごとに学習率を調整して振動を抑制する「AdaGrad」を組み合わせたアルゴリズムである。

* Adamax

無限大ノルムに基づいた Adam の派生形である。Embedding(埋め込み) モデルの場合において、Adamax は Adam よりも有用なことがある。

* Nadam

Adam と Nesterov momentum を組み合わせたアルゴリズムである。

* Adadelta

Adagrad の拡張版である。過去のすべての勾配を累積するのではなく、勾配更新の固定移動ウィンドウに基づいて、学習率を調整する。そのため、更新をたくさん行っても更新量がゼロにならない。複数の値を保持しないため、Adagrad に比べると省メモリである。

・ バッチサイズ

まとまりのある入力データのことをバッチと呼ぶ。バッチサイズとは、重みとバイアスを調整する際に、いくつの訓練データを単位に行うかを示す数である。バッチサイズが 1 より大きい場合では、損失関数の勾配を計算するときに、複数の訓練データの勾配の平均を算出する。そして、それをもとに重みとバイアスが調整される。例えば、訓練データが 30,000 個あるとき、バッチサイズを 100 とすると、100 個の訓練データの勾配平均を用いて 300 回のパラメータ調整が実行される。バッチサイズの最適な値は訓練データに依存する。バッチサイズを大きくする利点として、処理時間の短縮が挙げられる。理由は、「TensorFlow」や「NumPy」などの数値計算ライブラリは、大きな配列の計算を効率よく処理できるように最適化されているためである。また、バッチ処理を行うことで、入力データの読み込み命令数に対して演算命令数の割合を大きくすることができる。

・ エポック数

「1 エポック」とは学習において訓練データをすべて使い切ったときの回数に対応する。

例えば、訓練データが 30,000 個あるとき、バッチサイズを 100 とすると、100 個の訓練データの勾配平均を用いて 300 回のパラメータ調整が実行される。この処理が完了すると、すべての訓練データを 1 回使ったことになり、1 エポック目の処理が完了となる。

1.3.2 バイズ最適化 (BO)

BO は、計算リソースや実験リソースが多く必要となる問題において、試行回数を最小限に抑えて最適解を見出す手法である [9–11]。この手法は、主に目的関数の形状が不明なブラックボックス関数の場合や評価コストが高い場合に用いられる。特に、DL のハイパーパラメータのチューニング [25] や材料設計 [18] といった分野で、その有効性が示されている。この手法の欠点として「次元の呪い」が挙げられる。これは、次元が増加するにつれてモデルの複雑性が高まり、学習や推論が困難になる問題を指す。これを克服するための様々な手法が提案されている [26–32]。

BO の背景として、ベイズの定理とベイズ推定を理解する必要がある。

1.3.2.1 ベイズの定理 [33]

a 個の事象の組 $A_1, A_2, \dots, A_i, \dots, A_a$ が、互いに共通の根元事象を含まず、同時に標本空間を表現しているとする。このとき、この事象の組を標本空間の分割という。標本空間が a 個に分割されているとき、以下のように確率の総和は 1 となる。

$$\sum_{i=1}^a p(A_i) = 1 \quad (1.20)$$

ここで、別の分割 $B_1, B_2, \dots, B_i, \dots, B_a$ を考えると、事象 A_i と事象 B_j が同時に観察される確率は以下で示され、これを同時確率という。

$$p(A_i \cap B_j) \quad (1.21)$$

同時確率には以下のような性質がある。

$$\sum_{i=1}^a \sum_{j=1}^b p(A_i \cap B_j) = 1 \quad (1.22)$$

同時確率は、1 つの分割に関して足しあげると、以下のように残りの分割の確率になる。これを周辺確率という。

$$\sum_{i=1}^a p(A_i \cap B_j) = p(B_j) \quad (1.23)$$

$$\sum_{j=1}^b p(A_i \cap B_j) = p(A_i) \quad (1.24)$$

事象 A_i が観察されたという条件の下で, 事象 B_j が観察される確率は以下で求められる. これを条件付き確率という.

$$p(B_j|A_i) = \frac{p(A_i \cap B_j)}{p(A_i)} \quad (1.25)$$

条件付き確率の式 (1.25) の右辺の分母を移行すると, 確率の乗法定理が以下のように得られる.

$$p(A_i \cap B_j) = p(B_j|A_i)p(A_i) \quad (1.26)$$

乗法定理の式 (1.26) を周辺確率の式 (1.23) に代入すると, 全確率の公式が以下のように得られる.

$$p(B_j) = \sum_{i=1}^a p(B_j|A_i)p(A_i) \quad (1.27)$$

乗法定理の式 (1.26) は一般的な事象の性質を表現しているから, 式 (1.28) のように A_i と B_j を入れ替えても成り立つ.

$$p(A_i \cap B_j) = p(A_i|B_j)p(B_j) \quad (1.28)$$

式 (1.26), 式 (1.28), 式 (1.27) より, 確率に関するベイズの定理が式 (1.29) のように導かれる. このとき, $p(A_i)$ を事後確率, $p(A_i|B_j)$ を事後確率という.

$$p(A_i|B_j) = \frac{p(B_j|A_i)p(A_i)}{p(B_j)} = \frac{p(B_j|A_i)p(A_i)}{\sum_{i=1}^a p(B_j|A_i)p(A_i)} \quad (1.29)$$

1.3.2.2 ベイズ推定 [33]

分布に関するベイズの定理を式 (1.30) に示す. ここで, θ は母数であり, 確率変数として考える. $f(\theta)$ は事前確率分布, $f(\theta|X)$ は事後確率分布, $f(X|\theta)$ は尤度関数である. 式 (1.30) の分子は, 確率分布や尤度において母数と変数を含んだ部分であり, これをカーネルと呼ぶ. 分布に関するベイズの定理において, カーネルが確率分布や尤度の本質的な性質を決定する. 対して, 式 (1.30) の分母は正規化定数と呼ばれており, 確率分布の積分が 1 になるように設けられた, 母数を含まない部分である.

$$f(\theta|X) = \frac{f(X|\theta)f(\theta)}{f(X)} = \frac{f(X|\theta)f(\theta)}{\int_{-\infty}^{+\infty} f(X|\theta)f(\theta)d\theta} \quad (1.30)$$

ベイズ推定とは, 観測 X を得ることによって確率変数 θ の分布を更新することである. 確率変数の分布を表すために累積分布関数や確率密度関数がある.

ベイズ推定の手順を以下に示す.

1. 尤度関数 $f(X|\theta)$ をモデリングする. すなわち, 未知変数 θ のもとで観測 X が確率的に生成される過程を, 条件付き確率 $f(X|\theta)$ で書き下し, これを未知変数 θ の関数 $L(\theta) = f(X|\theta)$ とみなす. (X の関数とは考えない)
2. 事前確率 $f(\theta)$ をモデリングする. すなわち, 未知変数 θ のとり得る値の範囲と, その主観的な可能性の度合いを, 確率分布 $f(\theta)$ の形で表す.

3. ベイズの定理の式 (1.30) を適用して未知変数 θ の事後確率 $f(\theta|X)$ を求める.

ベイズ推定と最尤推定の違いについて説明する. まず, 尤度関数 $f(X|\theta)$ に基づいて未知のパラメータを知ろうとする点は同じである. しかし, 最尤推定は手元のデータが最も観測されやすいように母数 θ の尤もらしい値を推定する. 式 (1.31) のように尤度関数 $L(\theta) = f(X|\theta)$ の対数を取り, それを母数で微分してゼロと置いた尤度方程式を母数 θ について解く.

$$\frac{d}{d\theta} \log L(\theta) = 0 \quad (1.31)$$

このように最尤推定は尤もらしい値を点で推定したが, ベイズ推定は未知のパラメータや予測分布が確率分布の形で得られる. そして, ガウス過程を用いれば未知ベクトルの値について平均と共分散を持つガウス分布が得られるという利点がある.

1.3.2.3 ベイズ最適化 (BO) [34]

BO の目的は, 未知の目的関数 $f(\mathbf{x})$ が最大値を取るような入力ベクトル $\mathbf{x}^*$ を求めることである. 式 (1.32) に示す.

$$\mathbf{x}^* = \arg \max_{\mathbf{x}} f(\mathbf{x}) \quad (1.32)$$

未知の目的関数 $f(\mathbf{x})$ の形状の手がかりを得るために, 入力ベクトル $\mathbf{x} = \mathbf{x}_1, \mathbf{x}_2, \dots$ を任意に決めて実験することによって, 出力値 $y_1 = f(\mathbf{x}_1), y_2 = f(\mathbf{x}_2), \dots$ を求めることができる. しかし, 実験の種類によっては一実験を終えるのに多大なコストが発生するため, 実験コストを節約しつつ, 最適な $\mathbf{x}^*$ に近づくために, 毎回の実験において適切な入力ベクトル $\mathbf{x}_i$ を決めることが必要とされる. 例えば, 一つのニューラルネットワークを訓練するのに約 3 時間必要だとすると, グリッドサーチで最適な $\mathbf{x}^*$ を求めるのは多大な時間がかかってしまう. このような実験には BO が有用であると考えられる. BO では, N 回分の実験結果 $(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_N, y_N)$ が得られたときに, ガウス過程法に基づいて未知の目的関数 $f(\mathbf{x})$ を事後確率分布の形で推定する. $N+1$ 回目の実験では, $f(\mathbf{x})$ の事後確率分布を用いて次の実験パラメータ $\mathbf{x}_{N+1}$ を決める. $N+1$ 回目における実験の入力ベクトルの決め方を以下に示す.

1. 目的関数 $f(\mathbf{x})$ の推定結果として, 事後確率の期待値 $\mu(\mathbf{x})$ と標準偏差 $\sigma(\mathbf{x})$ を得る.
2. $\mu(\mathbf{x})$ と $\sigma(\mathbf{x})$ を組み合わせて定義した獲得関数 $a(\mathbf{x})$ が最大になるような $\mathbf{x}_{N+1}$ を次の実験の入力ベクトルとする.

BO の獲得関数として, 信頼性上限関数 UCB(Upper Confidence Bound), 信頼性下限関数 LCB(Lower Confidence Bound), 期待改善度 EI(Expected Improvement) などがある. それ

それ、式 (1.33), (1.34), (1.35) で表される.

$$a_{\text{UCB}}(\mu, \sigma, N) = \mu + \left(\sqrt{\frac{\log N}{N}} \right) \sigma \quad (1.33)$$

$$a_{\text{LCB}}(\mu, \sigma, N) = \mu - \left(\sqrt{\frac{\log N}{N}} \right) \sigma \quad (1.34)$$

$$\begin{aligned} a_{\text{EI}}(\mu, \sigma) &= \mathbb{E}[(f - \tau)I(f > \tau)] \\ &= (\mu - \tau)\Phi(t) + \sigma\phi(t) \end{aligned} \quad (1.35)$$

ここで, μ は期待値, σ は標準偏差, N はデータ点の数 (実験回数), $\sqrt{\frac{\log N}{N}}$ は探索 (exploration) と活用 (exploitation) の割合をコントロールする係数である. 探索とは, 標準偏差 σ が大きい領域を調べることであり, 未知の領域を攻めていくことを意味する. 活用とは, 現時点で分かっている最適値の付近を調べることである. 実験初期のようなサンプル点が少ない状況では探索重視にして, N が大きくなってきたら活用に重きを置くといった戦略があり, $\sqrt{\frac{\log N}{N}}$ はそれを反映している. 図 1.5 に σ の係数 $\sqrt{\frac{\log N}{N}}$ の遷移を示す. 横軸によって何回目の実験なのかが表され, 縦軸は $\sqrt{\frac{\log N}{N}}$ の値の大きさである. $N = 1$ では係数の値はゼロであり, $N = 3$ で係数の値は最大の 0.61 となり, 以降は減少していく.

a_{UCB} と a_{LCB} は式の形が似ているが, 最大値問題に対して UCB を用い, 最小値問題に対して LCB を用いる. UCB と LCB は, 推定の期待値 μ に対して, 標準偏差 σ に比例した大きさのマージンを加えた獲得関数であり, データ密度の低い箇所周辺を好んで探索する.

EI に関して, τ は N 回の観測 $y_N = f(\mathbf{x}_N)$ の中で最大の y であり, $t = \frac{\mu - \tau}{\sigma}$ は各 $\mathbf{x}$ において μ と τ の差を標準偏差 σ で正規化したものであり, $I(f > \tau)$ は $f > \tau$ が成り立つときに 1, 成り立たない時に 0 をとる指標関数である. そして, $\Phi(t)$ は標準正規分布の累積密度関数, $\phi(t)$




図 1.5 UCB, LCB の標準偏差 σ の係数の遷移

は標準正規分布の確率密度関数である。 a_{EI} では改善量が考慮されているため、「改善量は大きい改善確率は低い」場合を高く評価することができる。

以上のような獲得関数の中から一つ選択する。そして、獲得関数が最大になるような $\mathbf{x}$ における関数値 $f(\mathbf{x})$ を逐次的に実験で求め、推定値を更新しながら $f(\mathbf{x})$ を最大にする $\mathbf{x}^*$ に近づいていく。

1.3.3 遺伝的アルゴリズム (GA)

GA は、データ群をランダムに大量作成・評価し、高得点のものを次世代に残して交叉させ、突然変異を行い、それを何世代も繰り返して、優秀なデータ列を得る方法である。ランダム性があるため大域的なパラメータ探索に優れている。Holland がこの手法を提案した [14]。

GA の概略を図 1.6 に示す。まずは疑似乱数を用いて初期集団を生成する。1 つの個体は複数の遺伝子を持っており、個体集合はそれら個体が複数集まったもので構成されている。次にそれらの個体を自身で設定した適合度関数（評価関数）によって評価し、点数を付ける。付けられた点数が高い個体ほど高い確率で次世代に残すように選択する。そして交叉では、2 個体間の遺伝子を確率的に入れ替える。最後に、個体の遺伝子をランダムに変化させて、再度、適合度関数による評価をする。これらの処理を事前に設定した世代数に到達したら GA は終了となる。ここまでの処理を 1 試行とし、これを設計者の要求に応じて複数回実行する。

設計者が持つ時間や計算資源の状況に応じた最適な個体集合のサイズや試行回数の調整について説明する。まず、設計者に十分な時間と計算資源が確保されている場合、個体集合のサイズを小さくし（100 個程度）、試行回数を増やすことで（数百回）、非常に優れた解を得られる可能性が高くなる。この方法では、各試行の個体集合における最良解の特性に違いが生じるため、全体としてより優れた解を探索しやすくなる。一方で、設計者に十分な時間と計算資源が確保されていない場合には、個体集合のサイズを大きくし（数万個）、試行回数を 1 回にすることで、1 回の試行で比較的優れた解を得ることが可能となる。この方法では、多様な解を一度に探索することで、限られた計算リソースの中でも最適な解を見つけやすくする。

選択方式や交叉方式には以下のように複数の種類がある [35]。

・選択方式

＊ルーレット選択

それぞれの個体には、適合度に比例した大きさのルーレットの断片が与えられる。一集合の個体数を N とするとルーレットを N 回まわして、各試行で当たった個体が次世代の親の候補となる。ルーレットの断片の大きさ p_i は以下のように表される。ここで、 f_i は個体 i の適合度である。この方式は適合度がマイナスにならないことが前提になっている。欠点として、個体間の適合度の格差が激しい場合は適合度の高い個体を選ばれやすくなってしまい、局所解に陥りやすくなる。そのため、適合




図 1.6 GA の概略

度の正規化を行う必要がある。

$$p_i = \frac{f_i}{\sum_{k=1}^N f_k} \quad (1.36)$$

* ランキング選択

集合の各個体が適合度の大きさに順位付けられる。そして、各個体の選択確率が実際の適合度ではなく、その順位によって決定される方式である。これには、選択確率が適合度の格差に影響されないという利点がある。また、適合度の正規化を行う必要がない。しかし、毎世代で個体を適合度の大きさ順に並べる必要があり、処理に手間がかかってしまう場合がある。

* トーナメント選択

あらかじめ決めた数（トーナメントサイズ）だけ集合の中からランダムで個体を取り出し、その中で最も適合度の高い個体を選択し、次世代の親の候補とする。これを一集合の個体数 N 回実行する方式である。このとき復元抽出を実行するため、適合度の高い個体は次世代に複数残される可能性が高い。そのため、欠点としてトーナメントサイズを大きくしすぎると局所解に陥ってしまうことが挙げられる。

* エリート戦略

上記のような選択方式に付加させるもので、各世代における最良個体のいくつかを次世代に残すものである。もし、最良個体が選択されなかったり、交叉や突然変異で遺伝子が変わってしまうと、集合の最大適合度が下がってしまう可能性がある。これを避けるために、この戦略が導入されることがある。欠点として、エリート遺伝子が集合内で蔓延することで、遺伝子の多様性が失われてしまう可能性がある。

・交叉方式

＊一点交叉

遺伝子が交叉する場所 (交叉点) をランダムで一つ選び, その場所より後ろを入れ換える方式である. 概略を図 1.7 に示す. 例として, 8 層円筒の各層の比誘電率 ε を遺伝子とする. この方式には欠点がいくつか存在する. まず, 全ての可能なスキーマを形成できない. スキーマとは, 遺伝子型の部分集合のことであるが, 例えば, 「*」をワイルドカードとして, 「11*****1」と「*****1**」から「11***1*1」を形成することができない. また, スキーマ H の定義長 $\delta(H)$ が大きい場合は一点交叉だと破壊される可能性が高い. 定義長とはスキーマの一番左の*以外の文字と一番右の*以外の文字との距離のことであり, スキーマ H 「11***1*1」の定義長は $\delta(H) = 7$ である. もし「11***1*1」が最適解をもたらすとしたら, 一点交叉だとこのスキーマは高確率で破壊されてしまうため, 好ましくない. さらに, 短いスキーマが最適解をもたらすとしても, 一点交叉だとヒッチハイキングを引き起こす可能性がある. ヒッチハイキングとは, 必要なスキーマの一部ではないにもかかわらず, 有効なスキーマの近くに遺伝子座があるため, 交叉してもなお不要な遺伝子がスキーマに付いてくる現象である. そして, 両端のどちらかの遺伝子が常に交換されるため, 端の遺伝子座を優先してしまうという欠点もある.

＊二点交叉

概略を図 1.8 に示す. 交叉点をランダムに二つ選び, 二つの交叉点に挟まれている遺伝子をほかの個体と入れ換える方式である. この方式を用いることで, 一点交叉で問題になった長い定義長のスキーマを破壊してしまう可能性を下げられる. また, 端の遺伝子座を優先してしまう問題も解決される. しかし, 二点交叉であっても形成できないスキーマは存在する.

＊多点交叉

三点以上の交叉点をもつ方式である.

＊一様交叉

概略を図 1.9 に示す. それぞれの遺伝子を特定の確率で独立に入れ替える方式である. 確率 p は普通, $(0.5 \leq p \leq 0.8)$ の範囲内で設定される. この方式には位置的偏りがなく, ヒッチハイキングの問題を解消することができる. しかし, スキーマを非常に破壊しやすいという欠点を持つ.

本論文では, Python の分散進化アルゴリズムフレームワークである DEAP を用いて GA を実装した [36]. 交叉確率と突然変異確率を変数として扱い, 評価効率を高めた. これを適応型遺伝的アルゴリズム (AGA) と呼ぶことにする. 適応的な交叉確率 P_c および適応的な突然変異




図 1.7 一点交叉の概略




図 1.8 二点交叉の概略




図 1.9 一様交叉の概略

確率 P_m は、以下の式を用いて算出した [37].

$$P_c = \begin{cases} P_{ch} - \frac{(P_{ch} - P_{cl})(FV' - \overline{FV})}{FV_{\min} - \overline{FV}}, & FV' < \overline{FV}, \\ P_{ch}, & FV' \geq \overline{FV}, \end{cases} \quad (1.37)$$

$$P_m = \begin{cases} P_{mh} - \frac{(P_{mh} - P_{ml})(FV - \overline{FV})}{FV_{\min} - \overline{FV}}, & FV < \overline{FV}, \\ P_{mh}, & FV \geq \overline{FV}. \end{cases} \quad (1.38)$$

ここで、 P_{ch} および P_{cl} はそれぞれ最大および最小の交叉確率であり、 P_{mh} および P_{ml} はそれぞれ最大および最小の突然変異確率である。FV は各個体の適合度値を表し、優秀な個体は低い適合度値を持つと定義する。（ちなみに、第3章の光学クロック設計では、優秀な個体は低い適合度値を持つように適合度関数を定義したが、第4章のミリ波吸収体の設計では、優秀な個体は高い適合度値を持つように適合度関数を定義した。） FV' は交叉対象の2個体のうち、より小さい適合度値を持つ個体の適合度値である。 $FV_{\min}$ および $\overline{FV}$ は、その世代における個体の最小および平均の適合度値を示す。本論文では、確率の値はそれぞれ、 $P_{ch} = 0.9$, $P_{cl} = 0.5$, $P_{mh} = 0.9$, および $P_{ml} = 0.2$ とした。ある個体の特定の遺伝子が突然変異する確率は、 P_m と

P_{gene} の積で表される．ここで、 P_{gene} は遺伝子が突然変異する確率を表し、 P_m は個体ごとに突然変異が発生するかを判定する確率を示す．式 (1.37) および (1.38) は、適合度値が高い個体（優秀でない個体）に対して交叉と突然変異を促進することを意味する．この関係は図 1.10 に示されており、ここでは $P_{\text{ch}} = 0.9$, $P_{\text{cl}} = 0.5$, $P_{\text{mh}} = 0.9$, $P_{\text{ml}} = 0.2$, $FV_{\min} = 0.01$, および $\overline{FV} = 0.1$ を使用した．




図 1.10 式 (1.37), (1.38) に基づく適合度値 FV と P_c および P_m の関係.

第 2 章

遺伝的アルゴリズムの有効性

2.1 各手法の計算条件

本章では、多層媒質設計における GA の有効性を示すために、いくつかの手法の計算時間と最良解の得やすさを比較する。

多層円筒クロークの散乱断面積 (C_{sca}) の光学波長域における平均値を最小化する問題を考える。波長は $0.4 - 0.7 \mu\text{m}$ を $0.001 \mu\text{m}$ 刻みで計算した。多層円筒の C_{sca} の計算方法は後述の 3.3 節で述べる。

以下に、4 種類の手法について詳細を記述する。これらの計算条件は、以降の各節 2.2, 2.3, 2.4, 2.5 で共通である。ここで、A 層とは内側の対象物体から数えて奇数番目の層であり、B 層は偶数番目の層である。

- 適応型遺伝的アルゴリズム (AGA)

- 設定:

- * 個体数: 500
- * 世代数: 160 (2.5 節では 240)
- * 二点交叉確率: 適応型 (0.5 ~ 0.9)
- * 突然変異確率: 適応型 (0.2 ~ 0.9)
- * 遺伝子選択方式: トーナメント選択 (トーナメントサイズ 3)

- 停止条件: 最大計算時間 15 時間 (2.5 節では 40 時間)

- シンプルな遺伝的アルゴリズム (GA)

- 設定:

- * 個体数: 500
- * 世代数: 160 (2.5 節では 240)
- * 二点交叉確率: 固定値 0.5
- * 突然変異確率: 固定値 0.2
- * 遺伝子選択方式: トーナメント選択 (トーナメントサイズ 3)

– 停止条件: 最大計算時間 15 時間 (2.5 節では 40 時間)

• NN と AGA の組み合わせ (NN+AGA)

– 設定:

- * ニューラルネットワーク: 事前に学習済みの最適化モデル (TensorFlow/Keras)
- * 個体数: 20,000
- * 世代数: 300
- * 二点交叉確率: 適応型 (0.5 ~ 0.9)
- * 突然変異確率: 適応型 (0.2 ~ 0.9)
- * 遺伝子選択方式: トーナメント選択 (トーナメントサイズ 3)

– 停止条件: 最大計算時間 1.5 時間

• ベイズ最適化 (BO)

– 設定:

- * 初期サンプル数: 500
- * 最大イテレーション数: 600
- * 獲得関数: EI
- * モデルタイプ: ガウス過程

– 停止条件: 最大計算時間 15 時間 (2.5 節では 40 時間)

各手法で採用したライブラリは, GA は DEAP, NN は TensorFlow, BO は GPyOpt である.

NN と AGA を組み合わせた手法 (NN+AGA) では, 適合度関数の計算において, Mie 散乱理論を学習済みの NN を活用することで, 従来の計算のボトルネックであった波長ごとの逐次計算が解消され, GPU を用いた並列計算が可能になった [38]. これによって多層媒質の高速設計が可能になった. 探索空間の大きさを A とし, 探索数を B とすると, 探索割合は $(\frac{B}{A} \times 100)\%$ で表される. 探索割合が 2% の場合において, BO によりハイパーパラメータがチューニングされた NN モデルをミー散乱プログラムの代替として使用し, 高速にクロッキング条件を見出した. NN の学習に関する詳細は付録 A.1 に示した. NN を用いた設計は 2.2 節の未知パラメータが 4 個の場合のみ検討した. 試算では, 6 パラメータの場合は, データセットの用意に 20 日程度を要し, 8 パラメータの場合では, データセットの用意に 20 年程度を要する. そのため, 今回は実施しなかった.

AGA, GA, BO を用いた設計の計算時間を公平に評価するため, 同一のコンピュータ (インテル® Core™ i9-10900 プロセッサ) を使用した. NN と AGA を組み合わせた手法では, 別のコンピュータの GPU (NVIDIA Quadro RTX 5000) を用いて適合度関数を高速に計算した. 全ての手法において, 乱数シード値を変えて 10 回試行した.

2.2 未知パラメータが4個の場合

図 2.1 に示されている 8 層円筒クロークの両端 4 層の比誘電率を未知パラメータとした。偏光は TE 偏光とした。




図 2.1 8 層円筒構造の概略図

以下に本節における各設定を示す。

- 半径の設定:

- 対象物体の半径 (r_T): $0.5 \mu\text{m}$
- 最外層の半径 (r_8): $1.0 \mu\text{m}$
- 各層の厚さ (d): $\frac{0.5}{8} \mu\text{m} = 0.0625 \mu\text{m}$
- 各層の半径: $r_T, r_1, r_2, \dots, r_8$

- 比誘電率の設定:

- 対象物体の比誘電率: 9
- 外部媒質の比誘電率: 1
- 各層の比誘電率: $\epsilon_A^1, \epsilon_B^1, \dots, \epsilon_A^4, \epsilon_B^4$ (遺伝子に基づく設定)
- 中間層の比誘電率: 線形補間で取得

• 設計パラメータ:

– 遺伝子の範囲:

$$* \varepsilon_A^1, \varepsilon_A^4: 1 \leq \varepsilon \leq 15$$

$$* \varepsilon_B^1, \varepsilon_B^4: 0 < \varepsilon \leq 1$$

図 2.2 に各手法の進化過程を示す。横軸が累積計算時間 (hour) であり、縦軸が散乱断面積 C_{sca} の平均値である。それぞれの手法について、10 回の試行結果をプロットした。水色で示した NN+AGA は、初期段階で急激に C_{sca} の平均値が減少し、他の手法よりも 10 倍ほど高速に設計が完了した。NN+AGA の個体数 20,000 は AGA および GA と比較すると 40 倍多いため、初期世代における C_{sca} の平均値も小さかった。青色で示した GA は、9 時間程度で計算が完了し、 C_{sca} の平均値は他と比較して小さかった。赤色で示した AGA は、計算時間が長く、停止条件の 15 時間を迎えてしまったが、GA と同程度に小さい平均 C_{sca} を得た。緑色で示した BO は、試行による平均 C_{sca} にバラツキが見られる。4 つの手法はいずれも、15 時間以内に進化が十分に収束することが確認された。付録 A.2 には、各手法における世代ごとの計算時間と最良解の平均散乱断面積を示した。

訓練済み NN は BO によってハイパーパラメータが最適化されたとはいえ、予測誤差を持っているため、完全にミー散乱を表現できていないわけではない。そのため、NN と AGA を組み合わせた手法による結果には多少の誤差が生じている。図 2.3 の箱ひげ図において、各手法の相対的な優劣を比較するため、NN+AGA の散乱断面積をミー散乱プログラムで計算し直し、全てをミー散乱プログラムで統一して評価した。箱ひげ図には最適解として得られた 10 試行分のデータが含まれている。箱の中のオレンジ線は中央値であり、青の点線は GA によって達成された最小値を示している。AGA は分布が最小値側に寄っていることから、比較的安定して小さい平均 C_{sca} が得られる。GA は 4 手法において最も小さい平均 C_{sca} を得たが、AGA と比較するとデータの偏りがなく、正規分布に近い。中央値で比較すると、AGA よりも GA のほうが大きい。NN+AGA はデータの偏りが極端に小さく、特定の解に収束している。しかし、NN の予測誤差により、他手法の最小値よりも大きくなってしまった。BO は、最小値は GA とほぼ同一であるが、データのバラツキが最も大きくなった。

図 2.4 には、平均 C_{sca} の最小値に対応する散乱断面積スペクトルを示した。比較のため、灰色の実線で対象物体のスペクトルを併記している。4 手法のスペクトルはほぼ一致しており、対象物体の結果と比較すると、いずれの手法も一定のクロッキング性能を有していることが分かる。




図 2.2 未知パラメータが4個の場合の累積計算時間 (hour) における各最適化手法の平均散乱断面積. 各手法において10回試行した.




図 2.3 未知パラメータが4個の場合の異なる最適化手法における平均散乱断面積の比較を示した箱ひげ図. 橙色の線は中央値であり, 青の点線はGAによって達成された最小値を示す.




図 2.4 未知パラメータが 4 個の場合の異なる最適化手法における散乱断面積スペクトル.
比較のために, 灰色の実線で対象物体のみの散乱断面積を示した.

2.3 未知パラメータが6個の場合

6層円筒クロークの全層の比誘電率を未知パラメータとした。偏光は前節と同じく TE 偏光とした。以下に本節における各設定を示す。

- 半径の設定:

- 対象物体の半径 (r_T): $0.5 \mu\text{m}$
- 最外層の半径 (r_6): $1.0 \mu\text{m}$
- 各層の厚さ (d): $\frac{0.5}{6} \mu\text{m} = 0.0833 \mu\text{m}$
- 各層の半径: $r_T, r_1, r_2, \dots, r_6$

- 比誘電率の設定:

- 対象物体の比誘電率: 9
- 外部媒質の比誘電率: 1
- 各層の比誘電率: $\varepsilon_A^1, \varepsilon_B^1, \varepsilon_A^2, \varepsilon_B^2, \varepsilon_A^3, \varepsilon_B^3$ (全て遺伝子に基づいて設定)

- 設計パラメータ:

- 遺伝子の範囲:
 - * $\varepsilon_A^1, \varepsilon_A^2, \varepsilon_A^3$: $1 \leq \varepsilon \leq 15$
 - * $\varepsilon_B^1, \varepsilon_B^2, \varepsilon_B^3$: $0 < \varepsilon \leq 1$

図 2.5 に各手法の進化過程を示す。横軸が累積計算時間 (hour) であり、縦軸が散乱断面積 C_{sca} の平均値である。それぞれの手法について、10 回の試行結果をプロットした。緑色で示した BO では、試行による平均 C_{sca} にバラツキが見られる。特に、10 回の試行のうち、6 時間、7 時間、および 9.5 時間で計算が終了したケースでは、初期状態から平均 C_{sca} にほとんど変化がなかった。これらの場合、初期サンプル 500 個を生成する段階で、比誘電率プロファイルに 1 を含むケースが発生していた。その結果、最適解として比誘電率プロファイルに 1 が多く含まれる傾向が見られた。これは、対象物体付近の局所解に収束したことを示している。それ以外の 7 試行では、停止条件の 15 時間を迎えるほどに設計に時間を要した。青色で示した GA は 7 時間程度で全試行の設計が完了し、赤色で示した AGA は 12 時間程度で完了した。どちらも進化は十分に収束した。付録 A.3 には、各手法における世代ごとの計算時間と最良解の平均散乱断面積を示した。

図 2.6 に、最適解として得られた 10 試行分のデータを箱ひげ図として示す。箱の中の橙色線は中央値であり、青の点線は AGA によって達成された最小値を示している。いずれの手法においても、平均 C_{sca} の最小値はほぼ一致した。しかし、BO のバラツキは大きく、中央値は他 2 つの手法の最大値よりも大きくなってしまった。これは、BO を用いて 6 層円筒クロークを設計するためには、試行回数を重ねる必要があることを意味する。今回の場合では停止条件が 15 時間の設計を 10 試行実施したため、延べ 150 時間のリソースを要する。一方、AGA は GA よ

りもバラツキが小さかった。

図 2.7 には、平均 C_{sca} の最小値に対応する散乱断面積スペクトルを示した。比較のため、灰色の実線で対象物体のスペクトルを併記している。3 手法のスペクトルはほぼ一致している。対象物体の結果と比較すると、いずれの手法もクロージング性能は十分に高いとは言えない。この原因として、層数が 6 層と少ないことが挙げられる。




図 2.5 未知パラメータが 6 個の場合の累積計算時間 (hour) における各最適化手法の平均散乱断面積. 各手法において 10 回試行した。




図 2.6 未知パラメータが6個の場合の異なる最適化手法における平均散乱断面積の比較を示した箱ひげ図。橙色の線は中央値であり、青の点線は AGA によって達成された最小値を示す。




図 2.7 未知パラメータが6個の場合の異なる最適化手法における散乱断面積スペクトル。比較のために、灰色の実線で対象物体のみの散乱断面積を示した。

2.4 未知パラメータが 8 個の場合

8 層円筒クロークの全層の比誘電率を未知パラメータとした。偏光は前節と同じく TE 偏光とした。以下に本節における各設定を示す。

- 半径の設定:
 - 対象物体の半径 (r_T): $0.5 \mu\text{m}$
 - 最外層の半径 (r_8): $1.0 \mu\text{m}$
 - 各層の厚さ (d): $\frac{0.5}{8} \mu\text{m} = 0.0625 \mu\text{m}$
 - 各層の半径: $r_T, r_1, r_2, \dots, r_8$
- 比誘電率の設定:
 - 対象物体の比誘電率: 9
 - 外部媒質の比誘電率: 1
 - 各層の比誘電率: $\epsilon_A^1, \epsilon_B^1, \epsilon_A^2, \epsilon_B^2, \epsilon_A^3, \epsilon_B^3, \epsilon_A^4, \epsilon_B^4$ (全て遺伝子に基づいて設定)
- 設計パラメータ:
 - 遺伝子の範囲:
 - * $\epsilon_A^1, \epsilon_A^2, \epsilon_A^3, \epsilon_A^4$: $1 \leq \epsilon \leq 15$
 - * $\epsilon_B^1, \epsilon_B^2, \epsilon_B^3, \epsilon_B^4$: $0 < \epsilon \leq 1$

図 2.8 に各手法の進化過程を示す。横軸が累積計算時間 (hour) であり、縦軸が散乱断面積 C_{sca} の平均値である。それぞれの手法について、10 回の試行結果をプロットした。前節と同様に、緑色で示した BO では、試行による平均 C_{sca} にバラツキがみられる。停止条件である 15 時間に達しても進化が収束しなかったと推測されるケースが 4 つ存在した。また、初期状態から平均 C_{sca} が変化せず、7 時間で設計が完了したケースも確認された。一方、GA と AGA では進化が十分に収束していることが確認された。付録 A.4 には、各手法における世代ごとの計算時間と最良解の平均散乱断面積を示した。

図 2.9 に、最適解として得られた 10 試行分のデータを箱ひげ図として示す。箱の中の橙色線は中央値であり、青の点線は AGA によって達成された最小値を示している。AGA と GA に関しては、平均 C_{sca} の最小値はほぼ一致したが、BO はそれらと大きく離れていた。BO の最小値が、AGA および GA の最大値を上回った。この結果から、試行回数を増やしても、BO では高性能なクロッキング条件を得る可能性が低いと考えられる。

図 2.10 には、平均 C_{sca} の最小値に対応する散乱断面積スペクトルを示した。比較のため、灰色の実線で対象物体のスペクトルを併記している。3 手法のスペクトルは概ね一致している。対象物体の結果と比較すると、いずれの手法も一定のクロッキング性能を有していることが分かる。




図 2.8 未知パラメータが8個の場合の累積計算時間 (hour) における各最適化手法の平均散乱断面積. 各手法において10回試行した.




図 2.9 未知パラメータが8個の場合の異なる最適化手法における平均散乱断面積の比較を示した箱ひげ図. 橙色の線は中央値であり, 青の点線はAGAによって達成された最小値を示す.




図 2.10 未知パラメータが 8 個の場合の異なる最適化手法における散乱断面積スペクトル.
比較のために, 灰色の実線で対象物体のみの散乱断面積を示した.

2.5 未知パラメータが 16 個の場合

16 層円筒クロークの全層の比誘電率を未知パラメータとした。偏光は前節と同じく TE 偏光とした。以下に本節における各設定を示す。誘電率の範囲に関して、前節までは A 層が高誘電率層、B 層が低誘電率層だったが、本節では逆にした。さらに、高誘電率層の範囲の上限値を 15 から 30 に変更した。

- 半径の設定:

- 対象物体の半径 (r_T): $0.5 \mu\text{m}$
- 最外層の半径 (r_{16}): $1.0 \mu\text{m}$
- 各層の厚さ (d): $\frac{0.5}{16} \mu\text{m} = 0.03125 \mu\text{m}$
- 各層の半径: $r_T, r_1, r_2, \dots, r_{16}$

- 比誘電率の設定:

- 対象物体の比誘電率: 9
- 外部媒質の比誘電率: 1
- 各層の比誘電率: $\varepsilon_A^1, \varepsilon_B^1, \varepsilon_A^2, \varepsilon_B^2, \varepsilon_A^3, \varepsilon_B^3, \varepsilon_A^4, \varepsilon_B^4, \varepsilon_A^5, \varepsilon_B^5, \varepsilon_A^6, \varepsilon_B^6, \varepsilon_A^7, \varepsilon_B^7, \varepsilon_A^8, \varepsilon_B^8$ (全て遺伝子に基づいて設定)

- 設計パラメータ:

- 遺伝子の範囲:
 - * $\varepsilon_A^1, \varepsilon_A^2, \varepsilon_A^3, \varepsilon_A^4, \varepsilon_A^5, \varepsilon_A^6, \varepsilon_A^7, \varepsilon_A^8$: $0 < \varepsilon \leq 1$
 - * $\varepsilon_B^1, \varepsilon_B^2, \varepsilon_B^3, \varepsilon_B^4, \varepsilon_B^5, \varepsilon_B^6, \varepsilon_B^7, \varepsilon_B^8$: $1 \leq \varepsilon \leq 30$

図 2.11 に各手法の進化過程を示す。横軸が累積計算時間 (hour) であり、縦軸が散乱断面積 C_{sca} の平均値である。それぞれの手法について、10 回の試行結果をプロットした。前節と同様に、緑色で示した BO では、試行による平均 C_{sca} にバラツキがみられる。GA と AGA では進化が十分に収束していることが確認された。AGA は全ての試行において計算時間が最大の 40 時間だった。経過時間が 25 時間の時点で比較すると、最も小さい値を示したのは AGA であり、AGA が GA よりも優れた個体を生成していることが確認できる。付録 A.5 には、各手法における世代ごとの計算時間と最良解の平均散乱断面積を示した。

図 2.12 に、最適解として得られた 10 試行分のデータを箱ひげ図として示す。箱の中の橙色線は中央値であり、青の点線は AGA によって達成された最小値を示している。前節での 8 パラメータの場合、AGA と GA の平均 C_{sca} の最小値はほぼ同じであった。しかし、16 パラメータになるとその差が顕著となった。また、BO は AGA および GA の最大値を大幅に上回った。この結果から、試行回数を増やしても、BO では高性能なクロッキング条件を得る可能性が低いと考えられる。

図 2.13 には、平均 C_{sca} の最小値に対応する散乱断面積スペクトルを示した。比較のため、灰

色の実線で対象物体のスペクトルを併記している．対象物体のみの場合と BO の場合では散乱断面積がほぼ同程度であることから，BO による 16 層クロッキング媒質の設計は困難であると考えられる．一方，GA と AGA は可視光領域全体にわたり散乱断面積の低減に成功した．特に AGA は，最も効果的に散乱断面積を抑えることができた．




図 2.11 未知パラメータが 16 個の場合の累積計算時間 (hour) における各最適化手法の平均散乱断面積．各手法において 10 回試行した．




図 2.12 未知パラメータが16個の場合の異なる最適化手法における平均散乱断面積の比較を示した箱ひげ図. 橙色の線は中央値であり, 青の点線は AGA によって達成された最小値を示す.




図 2.13 未知パラメータが16個の場合の異なる最適化手法における散乱断面積スペクトル. 比較のために, 灰色の実線で対象物体のみの散乱断面積を示した.

2.6 結論

GA と AGA はいずれも進化が十分に収束し、他の手法と比較して安定した性能を示した。未知パラメータが 4 個の場合、GA が最も低い散乱断面積 C_{sca} を達成した。一方、未知パラメータが 6 個、8 個および 16 個の場合では、AGA が最小値を達成しており、複雑な設計問題に対して有効性を示した。ただし、AGA は設計に要する時間が長くなる傾向が見られた。GA および AGA のボトルネックは各個体の適合度値を算出する部分であり、ここを並列処理にすることで、所要時間の長さを解消することができる。

NN+AGA は他の手法に比べて約 10 倍の速さで設計が完了し、高速性が際立った。しかし、NN の予測誤差により、最適解の性能は GA や AGA より劣った。

BO は初期サンプル生成時の局所解への収束や試行間のばらつきが大きく、高性能なクロージング条件を得る可能性が低いことが示された。特に、試行回数を増やしても GA や AGA と比較して劣る結果となった。

層数が少ない場合（6 層、8 層）、いずれの手法も十分なクロージング性能を発揮できないことが確認された。一方で、層数が多い場合（16 層）の媒質設計においては、AGA が他の手法に対して優位性を持つことが確認された。これを受けて、次章では AGA を用いて 8 層以上の高性能なクロージング媒質を設計する。

第 3 章

広帯域な光学クロークの設計

3.1 概要

本章では, 広帯域な光学クロークの設計について述べる [39]. AGA を用いて, 無限長の円筒形対象物体に対する広帯域クロークを設計した. このクロークは $0.4 - 0.7 \mu\text{m}$ の波長範囲をカバーし, 可視光のほぼ全域にわたる. 媒質は, 同心多層円筒 (CM) で構成されている. 設計された 26 層以上の CM で覆われた対象物体の平均散乱断面積は, 覆われていない対象物体の断面積の 6% 以下に抑えられた. AGA によって設計された構造のクロッキング性能は, 座標変換光学と有効媒質近似を組み合わせた解析計算で設計されたものを上回った. 有限差分時間領域法によって計算された磁場の時間変化によりクロッキング性能を確認した. さらに, クロッキングのメカニズムについても議論した.

3.2 序論

不可視クロッキングはメタマテリアルにおいて魅力的な分野である [40–43]. これは, 対象物を不可視化する技術である. いくつかのクロッキング設計方法が提案されている. その一つは座標変換や等角写像に基づくクロッキングであり [44, 45], クロッキング媒質を設計して光が対象物を迂回するようにする方法である. 座標変換クロークの概要図を図 3.1 に示す. もう一つは, クロッキング媒質の分極が対象物の分極を打ち消すように設計する方法である [19, 20, 46–52]. 前者は広帯域の波長範囲に対応できると期待される一方, 後者は特定の共振波長においてのみクロッキングが可能である.

前者のクロッキング方法は Leonhardt [44] と Pendry ら [45] によって提案された. Pendry のクロッキングは, 光学周波数では非実用的である異方性と磁気応答を持つ不均一な媒質を必要とする. これに対して Cai らは, 光学周波数で磁気応答を持たない ($\mu = 1$) 実用的なクロッキング媒質のシミュレーションをおこなった [53]. 彼らは異方性を導入するために, 放射状に並ぶ金属ナノロッドを含む誘電体の円筒クロッキング媒質を提案した. しかし, 金属ナノロッドを放射状に埋め込み, かつ円筒中心からの距離に応じて配列密度を調節する必要があるため




図 3.1 座標変換クローク

作製が困難であるという問題点があった。これを受けて Huang らは、このクロッキング媒質を同心多層円筒構造（CM）からなる有効媒質に置き換え、光学周波数でのクロッキング媒質を報告した [54]。しかし、Huang の設計には 2 つの問題があり、クロッキング性能は高くなかった。一つは、ゼロ次元円筒場が対象物に侵入することであり [55]、もう一つは最外層と空気との間のインピーダンス不整合である [53, 54]。これらの問題を解決するために、NN を用いて高性能なクロッキング媒質を設計した報告例がある [15]。NN はメタマテリアル設計における強力なツールである [16]。しかしながら、更に高性能な媒質の設計に必要な大規模データセットの作成には、膨大な計算資源を必要とする。例えば、8 つの未知パラメータを予測するために約 400 億個の訓練データが必要である。このような大規模データセットを現実的に準備することは不可能である。

本研究では、NN に代わる手法として GA [56] を CM のクロッキング設計に採用する。GA はデータセットを使用せず、大規模な計算資源を必要としない。Mirzaei ら [20] および Yu ら [19] は GA を用いたクロッキング設計を報告しているが、これらのクロッキングは狭帯域である。我々は、可視光域全体（0.4 – 0.7 μm ）をほぼカバーする広帯域クロッキング構造の設計に成功した。

3.3 Mie 散乱理論 / 転送行列法

ここでは、Mie 散乱理論と転送行列法を用いた多層円筒の散乱断面積を導出する [57] [58]。

3.3.1 波動方程式

散乱断面積の導出に必要な散乱係数は、電場と磁場に対して円筒の内部と外部の境界条件を適用することで求めることができる。電場と磁場を円筒座標系で表す。電場と磁場はスカラー波動方程式の解を用いて表せるため、まずはスカラー波動方程式を以下に示す。

$$\Delta\psi + k^2 m^2 \psi = 0 \quad (3.1)$$

ここで、式 (3.1) は ψ の関数であり、 k は波数、 m は屈折率を表している。この式を満たす ψ を用いて、ベクトル $\mathbf{M}_\psi$ と $\mathbf{N}_\psi$ を以下のように定義する。

$$\mathbf{M}_\psi = \nabla \times (\psi \cdot \mathbf{a}_z) \quad (3.2)$$

$$mk\mathbf{N}_\psi = \nabla \times \mathbf{M}_\psi \quad (3.3)$$

$$mk\mathbf{M}_\psi = \nabla \times \mathbf{N}_\psi \quad (3.4)$$

ここで、 $\mathbf{a}_z$ は z 方向の単位ベクトルである。透磁率 $\mu = 1$ として、マクスウェル方程式から以下の式が導かれる。

$$\nabla \times \mathbf{H} = jkm^2\mathbf{E} \quad (3.5)$$

$$\nabla \times \mathbf{E} = -jk\mathbf{H} \quad (3.6)$$

ここで、 j は虚数単位である。式 (3.5), (3.6) を満たすように、式 (3.2), (3.3), (3.4) の解 u, v を選ぶと電場 $\mathbf{E}$ と磁場 $\mathbf{H}$ は以下のように表される。

$$\mathbf{E} = \mathbf{M}_v + j\mathbf{N}_u \quad (3.7)$$

$$\mathbf{H} = m(-\mathbf{M}_u + j\mathbf{N}_v) \quad (3.8)$$

また、円筒座標系では波動方程式の初期解が以下のように表される。

$$\psi_n = e^{jn\phi} Z_n(r\sqrt{m^2k^2 - h^2}) e^{jhz + j\omega t} \quad (3.9)$$

ここで、 n は整数、 h は任意の数、 Z_n は n 次のベッセル関数である。式 (3.9) を式 (3.2), (3.3) に代入して、ベクトル $\mathbf{M}_\psi$ と $\mathbf{N}_\psi$ が以下のように求められる。

$$\mathbf{M}_\psi = -\mathbf{a}_r \frac{jn}{r} \psi - \mathbf{a}_\phi \frac{\partial \psi}{\partial r} \quad (3.10)$$

$$\mathbf{N}_\psi = -\mathbf{a}_r \frac{jh}{mk} \frac{\partial \psi}{\partial r} - \mathbf{a}_\phi \frac{nh}{r} \psi + \mathbf{a}_z (m^2k^2 - h^2) \psi \quad (3.11)$$

次に、入射光の偏光方向とスカラー波動方程式の解 u, v の関係を調べるために、直交座標系におけるベクトル $\mathbf{M}_\psi$ と $\mathbf{N}_\psi$ を求める。真空中 (屈折率 $m = 1$) を x 軸と平行に進む平面波を考える。この平面波は以下のようなスカラー波動方程式 ψ_0 で表される。

$$\psi_0 = e^{j(kx - \omega t)} \quad (3.12)$$

式 (3.10), (3.11) を求めたときと同様に、式 (3.12) を式 (3.2), (3.3) に代入して、ベクトル $\mathbf{M}_\psi$ と $\mathbf{N}_\psi$ が以下のように求められる。

$$\mathbf{M}_\psi = \mathbf{a}_y jk\psi_0 \quad (3.13)$$

$$\mathbf{N}_\psi = \mathbf{a}_z k\psi_0 \quad (3.14)$$

スカラー波動方程式の解 u, v を用いて、以下のように電場 $\mathbf{E}$ と磁場 $\mathbf{H}$ を求める。

$$\mathbf{E} = \mathbf{a}_y jkv + \mathbf{a}_z jku \quad (3.15)$$

$$\mathbf{H} = -\mathbf{a}_y jku + \mathbf{a}_z jkv \quad (3.16)$$

式 (3.15), (3.16) より, $u = \psi_0, v = 0$ とすると, 電場 $\mathbf{E}$ は z 成分のみ, 磁場 $\mathbf{H}$ は y 成分のみであることがわかり, これは TM 偏光に対応している. また, $u = 0, v = \psi_0$ とすると, 電場 $\mathbf{E}$ は y 成分のみ, 磁場 $\mathbf{H}$ は z 成分のみであることがわかり, これは TE 偏光に対応している.

3.3.2 境界条件

散乱係数を求めるためには, 電場と磁場に対して円筒内部と外部の境界条件が必要である. そのため, 以降では境界条件を求める. 円筒の外部電場 $\mathbf{E}_1$, 磁場 $\mathbf{H}_1$ と内部電場 $\mathbf{E}_2$, 磁場 $\mathbf{H}_2$ とすると, 円筒内部と外部の境界では以下のような関係が成り立つ.

$$\mathbf{n} \times (\mathbf{E}_2 - \mathbf{E}_1) = 0 \quad (3.17)$$

$$\mathbf{n} \times (\mathbf{H}_2 - \mathbf{H}_1) = 0 \quad (3.18)$$

式 (3.17), (3.18) の $\mathbf{n}$ は境界面の法線ベクトルである. これらの式は, $\mathbf{E}_1$ と $\mathbf{E}_2$ の ϕ 成分と z 成分が等しく, 同様に $\mathbf{H}_1$ と $\mathbf{H}_2$ の ϕ 成分と z 成分が等しいことを意味する. 次に, 式 (3.7), (3.8) に式 (3.10), (3.11) を代入して, 円筒座標系における電場 $\mathbf{E}$ と磁場 $\mathbf{H}$ を求める.

$$\mathbf{E} = \mathbf{a}_r \left(-\frac{jn}{r} + \frac{h}{mk} \frac{\partial u}{\partial r} \right) + \mathbf{a}_\phi \left(-\frac{\partial v}{\partial r} - \frac{jnh}{mkr} u \right) + \mathbf{a}_z \frac{m^2 k^2 - h^2}{mk} ju \quad (3.19)$$

$$\mathbf{H} = \mathbf{a}_r \left(\frac{jmn}{r} u + \frac{h}{k} \frac{\partial v}{\partial r} \right) + \mathbf{a}_\phi \left(m \frac{\partial u}{\partial r} - \frac{jnh}{kr} v \right) + \mathbf{a}_z \frac{m^2 k^2 - h^2}{k} jv \quad (3.20)$$

$h = 0$ として ϕ 成分と z 成分を取り出す.

$$\mathbf{E}_\phi = -\frac{\partial v}{\partial r} \quad (3.21)$$

$$\mathbf{E}_z = jmk u \quad (3.22)$$

$$\mathbf{H}_\phi = m \frac{\partial u}{\partial r} \quad (3.23)$$

$$\mathbf{H}_z = jm^2 k v \quad (3.24)$$

波数 k は円筒内部と外部で変わらないため, 4 つの境界条件 ($\frac{\partial v}{\partial r}, mu, m \frac{\partial u}{\partial r}, m^2 v$) が得られる.

3.3.3 多層円筒構造の散乱

TE 偏光の場合では, 多層円筒構造のコア, l 個のシェル層, 多層円筒外側のスカラーポテンシャルは n 次のベッセル関数 J_n とハンケル関数 H_n を用いてそれぞれ以下のように表すこと

ができる.

$$v_{l+1} = \sum_{n=-\infty}^{\infty} F_n(J_n(m_{l+1}kr) - a_n^{l+1}H_n(m_{l+1}kr)) \quad \text{for: } r_l < r, \quad (3.25)$$

$$v_l = \sum_{n=-\infty}^{\infty} F_n(A_n^l J_n(m_l kr) - a_n^l H_n(m_l kr)) \quad \text{for: } r_{l-1} < r < r_l, \quad (3.26)$$

$$v_p = \sum_{n=-\infty}^{\infty} F_n(A_n^p J_n(m_p kr) - a_n^p H_n(m_p kr)) \quad \text{for: } r_{p-1} < r < r_p, \quad (3.27)$$

$$v_1 = \sum_{n=-\infty}^{\infty} F_n(A_n^1 J_n(m_1 kr) - a_n^1 H_n(m_1 kr)) \quad \text{for: } r_0 < r < r_1, \quad (3.28)$$

$$v_0 = \sum_{n=-\infty}^{\infty} F_n(A_n^0 J_n(m_0 kr)) \quad \text{for: } r < r_0. \quad (3.29)$$

ここで, m_0 は多層円筒構造のコア屈折率, $m_1, m_2, \dots, m_l$ はコアを覆う l 層のそれぞれのシェール比誘電率, m_{l+1} は多層円筒外部の媒質の屈折率である. r_0 はコア半径, $r_1, \dots, r_l$ は各シェールの半径である. $a_n^1, \dots, a_n^{l+1}, A_n^0, \dots, A_n^l$ は未定係数である. 式 (3.27) は p 層目 ($1 < p < l$) のスカラーポテンシャルである. これらの式において, ベッセル関数がある項は入射波に関係しており, ハンケル関数がある項は後退波に関係しているため, a_n^{l+1} が求めたい散乱係数である.

境界条件を解くことで未定係数 a_n^{l+1} を求める. TE 偏光の i - j 層目における境界条件は以下の式で表される.

$$m_i^2 v_i = m_j^2 v_j \quad (3.30)$$

$$\frac{\partial v_i}{\partial r} = \frac{\partial v_j}{\partial r} \quad (3.31)$$

式 (3.30), (3.31) を $r = r_0, r_1, \dots, r_l$ の場合についてそれぞれ考える. 円筒外部と l 層目間について, 以下ようになる.

$$m_{l+1}^2 J_n(m_{l+1}kr_l) - m_{l+1}^2 a_n^{l+1} H_n(m_{l+1}kr_l) = m_l^2 A_n^l J_n(m_l kr_l) - m_l^2 a_n^l H_n(m_l kr_l) \quad (3.32)$$

$$m_{l+1} J'_n(m_{l+1}kr_l) - m_{l+1} a_n^{l+1} H'_n(m_{l+1}kr_l) = m_l A_n^l J'_n(m_l kr_l) - m_l a_n^l H'_n(m_l kr_l) \quad (3.33)$$

l 層目と $(l-1)$ 層目間について, 以下ようになる. $p+1$ 層目と p 層目, p 層目と $(p-1)$ 層目も以下と同様な形になる.

$$\begin{aligned} m_l^2 A_n^l J_n(m_l kr_{l-1}) - m_l^2 a_n^l H_n(m_l kr_{l-1}) \\ = m_{l-1}^2 A_n^{l-1} J_n(m_{l-1} kr_{l-1}) - m_{l-1}^2 a_n^{l-1} H_n(m_{l-1} kr_{l-1}) \end{aligned} \quad (3.34)$$

$$\begin{aligned} m_l A_n^l J'_n(m_l kr_{l-1}) - m_l a_n^l H'_n(m_l kr_{l-1}) \\ = m_{l-1} A_n^{l-1} J'_n(m_{l-1} kr_{l-1}) - m_{l-1} a_n^{l-1} H'_n(m_{l-1} kr_{l-1}) \end{aligned} \quad (3.35)$$

1 層目とコア間について、以下ようになる。

$$m_1^2 A_n^1 J_n(m_1 k r_0) - m_1^2 a_n^1 H_n(m_1 k r_0) = m_0^2 A_n^0 J_n(m_0 k r_0) \quad (3.36)$$

$$m_1 A_n^1 J'_n(m_1 k r_0) - m_1 a_n^1 H'_n(m_1 k r_0) = m_0 A_n^0 J'_n(m_0 k r_0) \quad (3.37)$$

式 (3.32) から式 (3.37) の $2(l+1)$ 個の式を合わせた連立方程式を解くことによって、散乱係数 a_n^{l+1} が求められる。しかし、この連立方程式を直接解くと計算量が膨大になってしまうため、転送行列法を用いる [59]。

TE 偏光の境界条件について、式 (3.32) から式 (3.37) は以下のようにまとめることができる。ここで、式 (3.39) から式 (3.40) の間の式は省略してある。

$$A_n^0 \begin{pmatrix} m_0^2 J_n(m_0 k r_0) \\ m_0 J'_n(m_0 k r_0) \end{pmatrix} = M_{01} \begin{pmatrix} A_n^1 \\ a_n^1 \end{pmatrix} \quad (3.38)$$

$$M_{11} \begin{pmatrix} A_n^1 \\ a_n^1 \end{pmatrix} = M_{12} \begin{pmatrix} A_n^2 \\ a_n^2 \end{pmatrix} \quad (3.39)$$

$$M_{ll} \begin{pmatrix} A_n^l \\ a_n^l \end{pmatrix} = M_{l+1} \begin{pmatrix} 1 \\ a_n^{l+1} \end{pmatrix} \quad (3.40)$$

このとき、各 M は以下のように表される。

$$M_{01} = \begin{pmatrix} m_1^2 J_n(m_1 k r_0) & -m_1^2 H_n(m_1 k r_0) \\ m_1 J'_n(m_1 k r_0) & -m_1 H'_n(m_1 k r_0) \end{pmatrix} \quad (3.41)$$

$$M_{11} = \begin{pmatrix} m_1^2 J_n(m_1 k r_1) & -m_1^2 H_n(m_1 k r_1) \\ m_1 J'_n(m_1 k r_1) & -m_1 H'_n(m_1 k r_1) \end{pmatrix} \quad (3.42)$$

$$M_{12} = \begin{pmatrix} m_2^2 J_n(m_2 k r_1) & -m_2^2 H_n(m_2 k r_1) \\ m_2 J'_n(m_2 k r_1) & -m_2 H'_n(m_2 k r_1) \end{pmatrix} \quad (3.43)$$

$$M_{ll} = \begin{pmatrix} m_l^2 J_n(m_l k r_l) & -m_l^2 H_n(m_l k r_l) \\ m_l J'_n(m_l k r_l) & -m_l H'_n(m_l k r_l) \end{pmatrix} \quad (3.44)$$

$$M_{l+1} = \begin{pmatrix} m_{l+1}^2 J_n(m_{l+1} k r_l) & -m_{l+1}^2 H_n(m_{l+1} k r_l) \\ m_{l+1} J'_n(m_{l+1} k r_l) & -m_{l+1} H'_n(m_{l+1} k r_l) \end{pmatrix} \quad (3.45)$$

式 (3.38)～(3.45) より、多層円筒における境界条件の式は以下のようにまとめられる。

$$A_n^0 \begin{pmatrix} m_0^2 J_n(m_0 k r_0) \\ m_0 J'_n(m_0 k r_0) \end{pmatrix} = M_{01} M_{11}^{-1} M_{12} \cdots M_{ll}^{-1} M_{l+1} \begin{pmatrix} 1 \\ a_n^{l+1} \end{pmatrix} \quad (3.46)$$

$$T = \begin{pmatrix} T_{11} & T_{12} \\ T_{21} & T_{22} \end{pmatrix} = M_{01} M_{11}^{-1} M_{12} \cdots M_{ll}^{-1} M_{l+1} \quad (3.47)$$

$$\begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} m_0^2 J_n(m_0 k r_0) \\ m_0 J'_n(m_0 k r_0) \end{pmatrix} \quad (3.48)$$

そして、転送行列 T の要素を用いて散乱係数 A_n^0, a_n^{l+1} は以下のように表すことができる。

$$\begin{pmatrix} A_n^0 \\ a_n^{l+1} \end{pmatrix} = \frac{1}{T_{12}y - T_{22}x} \begin{pmatrix} -T_{11}T_{22} + T_{12}T_{21} \\ xT_{21} - yT_{11} \end{pmatrix} \quad (3.49)$$

結果として、散乱断面積 SCS は以下の式となる。ここで、 λ は波長である。

$$\begin{aligned} SCS &= \frac{2\lambda}{\pi} \sum_{n=-\infty}^{\infty} |a_n^{l+1}|^2 \\ &= \frac{2\lambda}{\pi} \left(2 \sum_{n=0}^{\infty} |a_n^{l+1}|^2 - |a_0^{l+1}|^2 \right) \end{aligned} \quad (3.50)$$

3.4 設計方法

無限長円筒の対象物体における座標変換型の不可視クロッキングについて説明する。クロークの形状を図 3.2(a) に示す。対象物体はクロッキング媒質で覆われている。ここで、 a および b はクロッキング媒質の内外の半径をそれぞれ表し、 r は中心からの距離である。円筒座標系 (r, θ, z) を設定し、 z 軸は円筒の長軸を表す。Pendry ら [45] は磁気応答を持つ場合のクロッキング条件を以下の式として示した。

$$\varepsilon_r = \mu_r = \frac{r-a}{r} \quad (3.51)$$

$$\varepsilon_\theta = \mu_\theta = \frac{r}{r-a} \quad (3.52)$$

$$\varepsilon_z = \mu_z = \left(\frac{b}{b-a} \right)^2 \frac{r-a}{r} \quad (3.53)$$

ここで、 $\varepsilon_r, \varepsilon_\theta, \varepsilon_z$ はそれぞれ半径方向、角度方向、円筒軸方向の比誘電率である。また、 μ_r, μ_θ, μ_z はそれぞれ半径方向、角度方向、円筒軸方向の比透磁率である。

光学周波数では、クロッキング媒質が磁気応答を持たないため、Cai ら [53] は次のような異方性誘電率と透磁率を導出した。この式は、透磁率 $\mu = 1$ とした座標変換に基づき、以下のよう記述される。（この座標変換を座標変換光学 (TO) とする。）

$$\varepsilon_r = \left(\frac{b}{b-a} \right)^2 \left(\frac{r-a}{r} \right)^2, \quad (3.54)$$

$$\varepsilon_\theta = \left(\frac{b}{b-a} \right)^2, \quad (3.55)$$

$$\mu_z = 1. \quad (3.56)$$

Huang ら [54] は、これらの関係が、図 3.2(b) に示されるような CM の有効媒質として実現可能であることを示した。有効媒質近似 (EMA) とは、媒質が複数の種類の組成を持つときに、図 3.3 のような近似モデルを用いることで実効的な比誘電率を求めることができる手法である [60, 61]。この構造では、低誘電率と高誘電率の層が交互に積層され、有効媒質を形成する。対象物体の比誘電率は ε_T 、対象物体に隣接する最初の層の比誘電率は ε_A^1 、次の層の比誘電率は ε_B^1 、最外層の比誘電率は ε_B^N である。層の総数は $2N$ である。各円筒の外半径は、




図 3.2 円筒クロークの形状. (a) 異方性媒質に覆われた対象物体. (b) CM に覆われた対象物体. $\mathbf{k}$ は入射光の波数ベクトルであり, $\mathbf{E}$ と $\mathbf{H}$ はそれぞれ電場および磁場を表す.




図 3.3 有効媒質近似. (a) 並列モデルと (b) 直列モデル

$r_A^1, r_B^1, r_A^2, r_B^2, \dots, r_A^N, r_B^N$ であり, 対象物体の半径は r_T である. 各層の厚みが等しい場合, 隣接する 2 層の有効誘電率は, 以下のような異方性有効媒質として近似される.

$$\varepsilon_\theta^i = \frac{\varepsilon_A^i + \varepsilon_B^i}{2}, \quad (3.57)$$

$$\frac{1}{\varepsilon_r^i} = \frac{1}{2} \left(\frac{1}{\varepsilon_A^i} + \frac{1}{\varepsilon_B^i} \right), \quad (3.58)$$

ここで, $i = 1, 2, \dots, N$ である. 式 (3.57) は図 3.3(a) の並列モデルを表現し, 式 (3.58) は図 3.3(b) の直列モデルを表現している. 式 (3.54), (3.55), (3.57), (3.58) を解くことで, 以下の解

析解が得られる.

$$\varepsilon_A^i = \left(\frac{b}{b-a}\right)^2 \left[1 \mp \sqrt{1 - \left(\frac{r_A^i - a}{r_A^i}\right)^2} \right], \quad (3.59)$$

$$\varepsilon_B^i = \left(\frac{b}{b-a}\right)^2 \left[1 \pm \sqrt{1 - \left(\frac{r_A^i - a}{r_A^i}\right)^2} \right]. \quad (3.60)$$

各層の比誘電率は, この関係を離散化することで決定される [54]. この手法は, TO と EMA を組み合わせたものであり, 以後「T/E」と呼ぶ. これにより, 各層の比誘電率を解析的に決定することが可能である. 我々の以前のアプローチは, 8 層 CM において, 式 (3.59), (3.60) の代わりに NN を用いて, 比誘電率 ε_A^1 , ε_B^1 , ε_A^4 , および ε_B^4 を予測するものであった [15]. 最適なクロッキング条件は, 比誘電率のパラメータスイープによって探した.

本研究では, CM のクロッキング設計において, 実数値エンコーディング方式を採用した GA を使用した [56]. この手法は, 目的関数がブラックボックスもしくは数理計画法が適用できない多峰性関数の場合に, 加えて現実的な時間で合理的な解を得たい場合に有用である. GA を採用した理由は, 設計された媒質が EMA に基づいており, 目的関数が不明であるためである. 対象物体の比誘電率は $\varepsilon_T = 9$ と設定した. 対象物体の半径および最外層の半径はそれぞれ, $r_T = 0.5 \mu\text{m}$ と $r_B^N = 1 \mu\text{m}$ である. GA での未知パラメータ数を減らすために, 各層の厚さを均等にした. $2N$ 層のクロッキング媒質を検討し, $2N$ の値として 8, 12, 16, 20, 26, 32 を採用した. したがって, 各層の厚さは $0.5 \mu\text{m}/(2N)$ である. 入射光の偏光は, 円筒の長軸に垂直な TE 偏光とした.

クロッキング指数 (CI) は, 広帯域クロッキング性能を評価するための適合度関数として用い, 以下のように定義した.

$$\text{CI} = \frac{\int_{\text{WL}} C_{\text{sca}}^{\text{cloak}}(\lambda) d\lambda}{\int_{\text{WL}} C_{\text{sca}}^{\text{uncloak}}(\lambda) d\lambda}, \quad (3.61)$$

ここで, $C_{\text{sca}}^{\text{cloak}}(\lambda)$ および $C_{\text{sca}}^{\text{uncloak}}(\lambda)$ は, それぞれ不可視化された物体と対象物体のみの散乱断面積 (SCS) を表す. WL は可視波長範囲 ($0.4 \mu\text{m} - 0.7 \mu\text{m}$) を意味する. SCS は, 3.3 節で説明した Mie 理論に基づく転送行列法により, 1 nm ごとに計算した.

GA を用いた媒質設計は, 可視波長範囲において最適なクロッキング条件を得るために, 最小の CI を見つけることを目的として実行した. GA には, Distributed Evolutionary Algorithms in Python (DEAP) フレームワーク [36] を使用し, 以下の条件下で実行した.

トーナメント選択サイズ	: 3
二点交叉確率	: 50% – 90%
突然変異確率	: 20% – 90%
集団サイズ	: 500

各モデルにおいて 60 個の疑似乱数を用いて試行した. 1.3.3 節で説明したように, 交叉確率と突然変異確率は, 評価効率を向上させるために可変とした (AGA). 世代数は, 総層数 ($2N$) に

応じて増加させ, 具体的には以下のようにした.

$2N = 8$ の場合	: 160 世代
$2N = 12$ の場合	: 160 世代
$2N = 16$ の場合	: 240 世代
$2N = 20$ の場合	: 320 世代
$2N = 26$ の場合	: 320 世代
$2N = 32$ の場合	: 640 世代

3.5 結果

まず, 8 層 CM を用いたクロージングを検討した. AGA を用いて各層の比誘電率が CI を最小化する条件を探索した. この計算では, 各層の比誘電率を 0 から 30 の範囲に設定した. 吸収によって不可視クロージングが抑制されるため, 損失を伴う媒質は考慮しなかった. 本研究では, 実数値の比誘電率を持つ媒質のみを扱った. AGA によって設計された 8 層 CM と対象物体のみの散乱スペクトルを図 3.4(a) に示す. 8 層 CM の SCS は対象物体のみの SCS より低かった. 最小の CI を示す比誘電率を図 3.4(b) にプロットした. 比誘電率が高い層と低い層が交互に積層されていることがわかる. この構造は, 式 (3.59), (3.60) の T/E で設計された構造と傾向が一致しており, AGA がクロージングのための CM 設計において合理的なパラメータを提供することを示唆している.




図 3.4 8 層 CM の設計結果. (a) AGA によって設計された 8 層 CM と対象物体のみの散乱スペクトル. AGA の実行では, ϵ_A および ϵ_B を 0 から 30 の範囲で設定した. (b) 8 層 CM の比誘電率プロファイル.

8層 CM では十分なクロッキング性能を得られなかったため、層の数を増やし、高い比誘電率と低い比誘電率を交互に積層する CM を設計した。設計可能なモデルとして、 $\varepsilon_A^i < \varepsilon_B^i$ (Model I) と $\varepsilon_A^i > \varepsilon_B^i$ (Model II) の2つがあるが、両モデルで結果が類似していたため、以降は Model I について論じる。Model II の結果は付録 B.1 にまとめた。比誘電率の範囲を $\varepsilon_A = 0-1$ および $\varepsilon_B = 1-30$ に設定し、AGA を用いた媒質設計を実行した。

図 3.5 に、波長範囲 $0.4\mu\text{m} - 0.7\mu\text{m}$ における、 $2N = 8, 12$, および 26 の SCS スペクトルを示した。また、対象物体のみの場合と、T/E で設計した 26 層 CM で覆われた対象物体の SCS スペクトルもプロットした。クロークなしの対象物体は全波長域で高い SCS を示した。概して、AGA を使用して設計した CM で対象物体を覆うと、散乱が大幅に低減した。26 層 CM で覆った対象物体（緑の実線）は、可視波長域で最も低い SCS を示した。これらの結果は、対象物体の比誘電率 $\varepsilon_T = 9$ に最適化されたクロッキング媒質を使用した場合のものである。

異なる比誘電率の対象物体について SCS を計算したところ、結果はほぼ同一であった。 ε_T に対する CI の依存性は付録 B.2 に示した。これにより、光が対象物体を迂回していることが示唆される。この結果は、後に示す FDTD のシミュレーション結果とも一致している。

図 3.6(a) および 3.6(b) に、それぞれ図 3.5 に示した SCS スペクトルを与える ε_A および ε_B を示した。これらは CM の中心からの半径方向距離 r の関数としてプロットした。また、T/E によって計算された比誘電率を黒の実線で示した。

全体として、AGA によって設計された ε_A は、T/E で得られた結果と似た傾向を示した。すなわち、 ε_A は r とともに増加した。興味深いことに、26 層および 32 層 CM において、特定の




図 3.5 AGA で設計した 8 (赤線), 12 (青線), 26 層 CM (緑線) の SCS スペクトル C_{sca} . 比較のため、対象物体のみ (黒線) および T/E で設計した 26 層 CM (緑の点線) を示した。




図 3.6 各 CM の比誘電率プロファイル. (a) ϵ_A および (b) ϵ_B を中心からの半径方向距離 r の関数として示す.

r で大きな誘電率 ($\epsilon_A \approx 1$) を示した. 具体的には, 26 層 CM では $r = 0.94 \mu\text{m}$, 32 層 CM では $r = 0.92 \mu\text{m}$ である.

対して, AGA によって設計された ϵ_B は, T/E で得られた ϵ_B から大きく逸脱していた. また, 26 層および 32 層 CM では, 特定の r で大きな誘電率を示した. 具体的には, 26 層 CM では $r = 0.62 \mu\text{m}$, 32 層 CM では $r = 0.66 \mu\text{m}$ である. すべての CM において, AGA は外層の ϵ_B を小さく設計しており, これによって空気とのインピーダンス整合が実現した.

図 3.7 に, 各 CM の $2N$ に対する CI をまとめた. T/E に基づく 2 つのモデル (Model I と Model II) があるが, どちらのモデルも層数を 128 にまで増やしても十分なクロッキング性能を示さなかった. 一方, AGA は層数が増加するにつれて良好な広帯域クロッキング性能を発揮した. AGA の結果に関して, 3 種類の CI を示した. 1 つ目は, ϵ_B の範囲を 1 から 10 に設定した場合の設計で得られた CI (オレンジ色の線) である. 2 つ目は, $\epsilon_B = 1 - 16$ の場合の AGA 計算で得られた CI (水色線) である. 3 つ目は, $\epsilon_B = 1 - 30$ の場合の AGA 計算で得られた CI (緑線) である. いずれの場合も, ϵ_A の範囲は $0 - 1$ である. ϵ_B の範囲が広がるにつれて CI は低下, つまりクロッキング性能が向上した. 実際の低損失な材料, 例えば Si の最大比誘電率は 20 未満であるため, 実材料を使用して AGA で十分に低い CI を持つクロッキング媒質を設計することが可能である. すべての場合において, AGA によって設計されたクロッキング性能は, T/E で設計されたものよりも桁違いに優れている.

AGA では, ランダムな交叉および突然変異が実行されるため, 試行回数を重ねる必要があった. 図 3.7 には, 60 回の AGA 試行で得られた最低 CI を示した. しかし, この図だけでは,




図 3.7 各 CM の層数に対する CI の変化. T/E を用いて解析的に設計された CM では, 層数を増やしても高い CI を示す. 一方, AGA によって設計された CM は, 層数を増やすことで CI が減少し, 高いクロッキング性能が得られる. 図中の数値は層数を示す.

AGA が最適なクロッキング媒質を得る確率を評価することはできない. そのため, 60 回の全試行で得られた CI の分布を, 箱ひげ図を用いて図 3.8 に示した. 箱の中央にあるバーは中央値を示し, 箱の上端と下端はそれぞれ第 3 四分位数と第 1 四分位数を示している. 図 3.8(a) – (c) は, 異なる ϵ_B の範囲で設計された CM の CI を示しており, ϵ_B の範囲はそれぞれ (a) 1 – 10, (b) 1 – 16, (c) 1 – 30 である.

ϵ_B の探索範囲が広がると, CI の分布の幅が広くなり, 中央値が高くなるが, 最低の CI 値は低くなった. 図 3.8(c) では, 26 層 CM で最低の CI が得られたが, 32 層 CM の中央値は 26 層 CM の中央値よりも低かった. このことは, 26 層 CM での最低値が確率的な偶然によって得られたことを示唆している. 計算資源と計算時間が許せば, 層数を増やすことでより良い結果が得られる可能性がある.

図 3.9(a) および (b) に, 対象物体のみの場合と, 26 層 CM で覆われた対象物体の磁場 H_y 分布を示した. 有限差分時間領域法 (FDTD) を用いてこれらをシミュレーションした (FullWAVE, Synopsys Inc.). 26 層 CM は条件 $\epsilon_B = 1-30$ の AGA により設計されたものである. 入射光は波長 $0.54 \mu\text{m}$ の平面波であり, z 軸の負方向から正方向に入射させた. 偏光方向は x 軸方向である.

図 3.9(a) は, クロッキングが施されていない場合を示し, 波面が乱れ, 入射光が強く散乱されていることが分かる. 一方, 図 3.9(b) では, 対象物体がクロッキング媒質で覆われている場合の波面が示されており, 波面の乱れが見られなかった. これは光が対象物体を迂回していることを示している. 対象物体内部の磁場は緑色で示されているように弱く, 光が内部に侵入して




図 3.8 AGA を 60 回試行して得られた各 CM の CI を示す箱ひげ図. (a) $\epsilon_B = 1-10$, (b) $\epsilon_B = 1-16$, (c) $\epsilon_B = 1-30$. 図中の数値は層数を示す.

いないことが確認できた. 図中の黒い実線はエネルギーの流れを示している. 図 3.9(b) の下部には, クローキング媒質の一部を拡大した図が示されており, 層構造の輪郭とエネルギーの流れが描かれている. 拡大図から, 内側の 6 層にはほとんどエネルギーの流れが存在しないことが確認できる.




図 3.9 磁場の y 方向成分 (H_y) のスナップショット. (a) 対象物体のみの場合, (b) AGA によって設計された 26 層 CM ($\varepsilon_B = 1-30$ の条件) で覆われた対象物体の場合を, FDTD でシミュレーションした結果. (b) の下部には拡大図が示され, エネルギーの流れが黒い実線で描かれている. 赤線は各層の輪郭を示す.

3.6 考察

T/E は CM の設計において重要であるが, 図 3.7 に示されているように, T/E で設計された 128 層 CM よりも AGA で設計された 12 層 CMの方がはるかに優れたクロッキング性能を示した. この理由として以下の 3 点が考えられる.

1. CM と周囲の空気との間でインピーダンス不整合が生じ, CM 外層で散乱が発生すること.
2. ゼロ次円筒波が対象物体に浸透すること [53, 54].
3. T/E で用いられる式 (3.57), (3.58) に基づく EMA が十分ではないこと.

上記のうち, (1) と (2) は磁気応答を持たないクロッキング媒質 ($\mu = 1$) を用いることに起因し, (3) は隣接する 2 つの層のみを考慮した EMA に起因する.

これを理解するために, 図 3.10 に, AGA により設計された 26 層 CM の有効誘電率 ε_r および ε_θ を黒の実線で示した (範囲 $\varepsilon_A = 0-1$, $\varepsilon_B = 1-30$). これらは式 (3.57) および式 (3.58) を用いて計算されたものである. 他の層数の CM に関する結果は, 付録 B.3 に示した. 式 (3.54) および式 (3.55) を用いて算出された ε_r および ε_θ を青の点線 (TO) でプロットした.




図 3.10 AGA で設計された 26 層 CM の異方性誘電率. (a) ε_r および (b) ε_θ を中心からの半径方向距離 r の関数として示す ($\varepsilon_A = 0-1$, $\varepsilon_B = 1-30$).

AGA と TO の誘電率プロファイルは一致しない．これは、TO が最適解ではないためである．TO で設計された CM は、表面でのインピーダンス整合や対象物体による散乱の除去を考慮していない．一方、AGA を用いることで、これらの CI を増加させる要因が自動的に解消され、低 CI を有する CM が設計できた．この点を示すために、CM を以下の 3 つの領域に分けた．

Region I : $r = 0.50\text{--}0.62\ \mu\text{m}$

Region II : $r = 0.62\text{--}0.92\ \mu\text{m}$

Region III : $r = 0.92\text{--}1.0\ \mu\text{m}$

Region I の最外層の有効誘電率 ε_θ は高く、この層はインピーダンス不整合によって対象物体を遮蔽する役割を果たしている．図 3.9 (b) に示すように、入射光のエネルギーの流れは Region I の外側を沿い、Region I の内側を通過する光エネルギーはほとんど無視できる．このような遮蔽層は、以前の研究 [62, 63] で提案されており、それらでは完全電気導体が遮蔽層として使用されている．AGA の利用により、高い比誘電率を持つ層が遮蔽効果を発揮することが明らかになった．

Region III における ε_θ のなだらかな減少は、周囲の空気とのインピーダンス整合を果たし、光の散乱を低減する．一方、Region II は光を迂回させる役割を果たす媒質としてみなされる．Region II の比誘電率 ε_r および ε_θ を、半径 $a' = 0.62\ \mu\text{m}$ および $b' = 0.92\ \mu\text{m}$ として式 (3.54), (3.55) を用いて計算し、「Corrected TO」として赤の破線で図示した．この「Corrected TO」は、有効クロッキング領域（Region II）に対応しており、AGA で得られた比誘電率プロファイルと一致している．

結果として、高いクロッキング性能を持つ媒質を設計するためには、光の迂回、外部とのインピーダンス整合、および対象物体の遮蔽を考慮する必要があると判明した（図 3.11）．AGA による設計ではこれらすべての要因が自動的に考慮された．そのため、AGA はクロッキング設計における強力なツールであるといえる．

3.7 結論

AGA を用いて、無限長の円筒物体のための超広帯域不可視クロークを設計した．このクロークは $0.4\ \mu\text{m}$ から $0.7\ \mu\text{m}$ の帯域幅を持ち、可視光範囲のほぼ全域をカバーした．26 層以上の最適化された CM で対象物体を覆うことで、平均散乱断面積を対象物体のみの散乱断面積の 6% 以下にまで減少させた．AGA で設計した構造のクロッキング性能は、TO および EMA に基づく解析計算による設計を上回った．高性能なクロッキング媒質を設計するために、光の迂回、周囲空気とのインピーダンス整合、対象物体の遮蔽を考慮した．AGA はこれらすべての要素を自動的に取り込むことで、クロッキング媒質の設計において強力なツールとなった．媒質の周波数分散は本研究で考慮しなかったが、実際の物質ではその存在は避けられない．特に広帯域ク




図 3.11 AGA で設計した 26 層クロークのインピーダンスプロファイル

ローキングでは、周波数分散を取り入れた設計が重要である。この問題を解決するための設計手法を今後提案する必要がある。

第 4 章

ミリ波吸収体の設計

4.1 概要

本章では、自動車レーダー周波数向けのミリ波吸収体の設計について述べる [64]. AGA を用いて、ミリ波を対象とした薄膜吸収体を設計した. この吸収体は、ポリジメチルシロキサンにグラファイトを分散させた複合材料の多層構造である. 設計された吸収体は、厚さ 0.3 mm の場合、自動車レーダー周波数帯域 (76 – 81 GHz) において 20 dB (99%) 以上の吸収率を示し、厚さ 0.5 mm の場合、W バンド (75 – 110 GHz) 全域において 20 dB 以上の広帯域吸収を実現した. これらの薄膜吸収体は、先進運転支援システムの安定した運用に寄与することが期待される.

4.2 序論

先進運転支援システム (ADAS) が、運転者、乗客、および他の道路利用者の安全を確保するために導入されている. 定速走行・車間距離制御装置および衝突回避機能は 76 – 77 GHz の周波数帯域で動作し、死角検知システムおよび車線変更支援は 77 – 81 GHz の周波数帯域を利用する. 先行研究では、高速道路上の大量の車両レーダーセンサー間の信号伝搬をシミュレーションし、複数の信号が受信機に到達することが示された [65]. これにより、干渉が発生し、ゴーストターゲットの生成や信号対雑音比 (SNR) の低下を招く可能性がある. これらは ADAS の性能に悪影響を及ぼす恐れがある. さらに、現在のレーダー帯域を超える高周波数帯の利用が、角度分解能および精度の向上、ならびにアンテナサイズの縮小に寄与すると期待されている [66].

ミリ波吸収体は、薄型化と広帯域吸収の両立を目標に開発されてきた. しかし、従来提案されてきた吸収体は、これらの要件を両立することが困難であった [67]. スクリーン印刷によって作製された抵抗性の正方形パッチ型周波数選択表面で構成されるレーダー吸収体は、75 – 82 GHz 帯域で 20 dB (99%) を超える吸収率を示した [68]. しかし、この吸収体は、高精度な表面パターンや正確な厚みの制御が必要であり、大量生産には適していない. 他の論文では、厚さ 1 mm のグラフェンフォーム吸収体が、7 – 18 GHz, 27 – 40 GHz, 75 – 110 GHz の各帯域

で 90% を超える広帯域吸収率を提供したことを報告している [69]. この吸収体は複雑な製造工程で作製されたものである. このような複雑な構造を持つ吸収体は, 薄型化および特定の用途に適した吸収帯域を有するが, 製造の複雑さや大面積での生産の難しさから, 実用的ではない. 他方, 広帯域吸収体を開発するために, 多層構造の吸収体を利用可能である [70–73]. さらに, グラフェンは高い導電性と軽量性を持つため, 極めて薄く軽量な吸収体の開発が可能である [69, 74–76]. したがって, グラファイト/ポリマー複合材料からなる多層構造は, 広帯域吸収, 薄型化, および軽量化を同時に実現できる可能性がある.

本研究では, 自動車用レーダー向けに, グラファイトを分散させたポリジメチルシロキサン (PDMS) からなる高吸収率, 薄型, かつ実用的に製造可能な多層吸収体 (MLA) を設計した. このような MLA を設計するためには, 多くの未知パラメータを決定する必要がある. ニューラルネットワークを用いた機械学習は, この種の問題を解決するための最も強力なツールの一つである. しかし, 膨大なデータセットが必要であり, それらを準備することは現実的ではない場合がある [39]. そこで本研究では GA を採用した [56]. このアプローチは, 多層構造のパラメータを最適化するためには効果的な戦略である [19, 20, 77–79]. 本研究では, 2 種類の MLA を検討した. 一つは自動車用レーダー周波数帯 (76 – 81 GHz, 本論文では ARF バンドと定義する) 向けの狭帯域 MLA であり, もう一つは W バンド (75 – 110 GHz) をカバーする広帯域 MLA である. 後者は将来的な用途での利用が期待される. 各帯域において 20 dB 以上の吸収率を持つ MLA を設計することを目標とし, 結果として両タイプの吸収体の最適化に成功した.

4.3 フレネル方程式 / 転送行列法

4.3.1 透過と反射 (界面)

電磁波が平面波の場合, マクスウェル方程式から以下のような電場 $\mathbf{E}$, 磁場 $\mathbf{H}$ 及び波数ベクトル $\mathbf{k}$ の関係が導かれる.

$$\mathbf{k} \times \mathbf{E} = \mu\omega\mathbf{H} \quad (4.1)$$

$$\mathbf{k} \times \mathbf{H} = -\varepsilon\omega\mathbf{E} \quad (4.2)$$

ここで, μ は媒質の透磁率, ε は媒質の誘電率, ω は各周波数である. 屈折率 n を用いて $\mathbf{k} = nk_0$ より, 式 (4.1) は等方性媒質の場合に次式で表される.

$$\mathbf{H} = \frac{k_0}{\mu\omega} n \mathbf{E} \quad (4.3)$$

スネルの法則は次の式で表される.

$$n_1 \sin \theta_1 = n_2 \sin \theta_2 \quad (4.4)$$

ここで n_i , θ_1 , θ_2 は各層の媒質の屈折率, 入射角および屈折角である. 入射角 θ_1 を知ることで, 反射角 θ_1 および屈折角 θ_2 を知ることができる. 屈折角 θ_{i+1} は式 (4.4) を用いて以下の式で求

められる.

$$\theta_{i+1} = \sin^{-1} \left(\frac{n_i}{n_{i+1}} \sin \theta_i \right) \quad (4.5)$$

一つの媒質の界面に光が入射した際の, s-偏光 (電場が入射面に垂直な偏光) と p-偏光 (電場が入射面内の偏光) における反射率と透過率を考える. そのために, 反射係数 r と透過係数 t を導出する.

まずは s-偏光の入射光に対する反射係数 r_s と透過係数 t_s を求める. 入射光の電場を E_1^+ , 反射光の電場を E_1^- , 透過光の電場を E_2^+ とする. 界面における電場と磁場の表面成分は連続するため, 次式が成り立つ.

$$E_1^+ + E_1^- = E_2^+ \quad (4.6)$$

$$H_1^+ \cos \theta_1 - H_1^- \cos \theta_1 = H_2^+ \cos \theta_2. \quad (4.7)$$

式 (4.3) から, 式 (4.7) は次のようになる.

$$\frac{k_0}{\mu_1 \omega} n_1 E_1^+ \cos \theta_1 - \frac{k_0}{\mu_1 \omega} n_1 E_1^- \cos \theta_1 = \frac{k_0}{\mu_2 \omega} n_2 E_2^+ \cos \theta_2. \quad (4.8)$$

磁気応答がない場合, μ は一定であり, k_0 と ω は媒質によらず一定であるため, 以下のようになる.

$$n_1 E_1^+ \cos \theta_1 - n_1 E_1^- \cos \theta_1 = n_2 E_2^+ \cos \theta_2. \quad (4.9)$$

反射係数 r は入射光の振幅に対する反射光の振幅の比 $\frac{E_1^-}{E_1^+}$ であり, 透過係数 t は入射光の振幅に対する透過光の振幅の比 $\frac{E_2^+}{E_1^+}$ である. 式 (4.6) と式 (4.9) の連立方程式を解くと, 次式の反射係数 r_s と透過係数 t_s が得られる.

$$r_s = \frac{n_1 \cos \theta_1 - n_2 \cos \theta_2}{n_1 \cos \theta_1 + n_2 \cos \theta_2} \quad (4.10)$$

$$t_s = \frac{2n_1 \cos \theta_1}{n_1 \cos \theta_1 + n_2 \cos \theta_2} \quad (4.11)$$

同様にして, p-偏光の場合も電場と磁場の境界条件を解くと, 以下の式が得られる.

$$r_p = \frac{n_2 \cos \theta_1 - n_1 \cos \theta_2}{n_2 \cos \theta_1 + n_1 \cos \theta_2} \quad (4.12)$$

$$t_p = \frac{2n_1 \cos \theta_1}{n_2 \cos \theta_1 + n_1 \cos \theta_2} \quad (4.13)$$

反射光の強度を入射光の強度で割ったものが反射率 R である. そして, 透過光の強度を入射光の強度で割ったものが透過率 T である. 入射光強度 I_1^+ , 反射光強度 I_1^- , 透過光強度 I_2^+ は

真空のインピーダンス Z_0 を用いて以下のように表される.

$$I_1^+ = \frac{n_1 |E_1^+|^2}{2Z_0} \quad (4.14)$$

$$I_1^- = \frac{n_1 |E_1^-|^2}{2Z_0} \quad (4.15)$$

$$I_2^+ = \frac{n_2 |E_2^+|^2}{2Z_0} \quad (4.16)$$

式 (4.14), (4.15) および (4.16) より, 反射率 R と透過率 T は以下のように求められる.

$$R = \frac{I_1^-}{I_1^+} = |r|^2 \quad (4.17)$$

$$T = \frac{I_2^+}{I_1^+} = \frac{n_2 \cos \theta_2}{n_1 \cos \theta_1} |t|^2 \quad (4.18)$$

エネルギー保存の法則に基づき, 無損失の媒質では透過率 T と反射率 R の和は次の式で表される.

$$R + T = 1 \quad (4.19)$$

吸収率 A の損失媒質では, 以下の式が成り立つ.

$$R + T + A = 1 \quad (4.20)$$

4.3.2 透過と反射 (多層問題)

多層媒質の反射率 R と透過率 T を求める. 層数 N が多い場合は, 転送行列法が用いられる [59]. 多層膜における電磁波伝搬の様子を図 4.1 に示す. s-偏光の場合において, 層 i と層 j の間には以下のような電場と磁場の連続条件がある.

$$\phi_i^+ E_i^+ + \phi_i^- E_i^- = E_j^+ + E_j^- \quad (4.21)$$


$$-k_i \cos \theta_i \phi_i^+ E_i^+ + k_i \cos \theta_i \phi_i^- E_i^- = -k_j \cos \theta_j E_j^+ + k_j \cos \theta_j E_j^- \quad (4.22)$$

これらを以下のように行列形式に直す.

$$\begin{pmatrix} 1 & 1 \\ -k_i \cos \theta_i & k_i \cos \theta_i \end{pmatrix} \begin{pmatrix} \phi_i^+ & 0 \\ 0 & \phi_i^- \end{pmatrix} \begin{pmatrix} E_i^+ \\ E_i^- \end{pmatrix} = \begin{pmatrix} 1 & 1 \\ -k_j \cos \theta_j & k_j \cos \theta_j \end{pmatrix} \begin{pmatrix} E_j^+ \\ E_j^- \end{pmatrix} \quad (4.23)$$

この行列に右辺の逆行列をかけ, 以下のように式変形する.

$$\begin{aligned} \begin{pmatrix} E_j^+ \\ E_j^- \end{pmatrix} &= \begin{pmatrix} 1 & 1 \\ -k_j \cos \theta_j & k_j \cos \theta_j \end{pmatrix}^{-1} \begin{pmatrix} 1 & 1 \\ -k_i \cos \theta_i & k_i \cos \theta_i \end{pmatrix} \begin{pmatrix} \phi_i^+ & 0 \\ 0 & \phi_i^- \end{pmatrix} \begin{pmatrix} E_i^+ \\ E_i^- \end{pmatrix} \\ &= \frac{1}{t_{ji}} \begin{pmatrix} 1 & r_{ji} \\ r_{ji} & 1 \end{pmatrix} \begin{pmatrix} \phi_i^+ & 0 \\ 0 & \phi_i^- \end{pmatrix} \begin{pmatrix} E_i^+ \\ E_i^- \end{pmatrix} \\ &= M_{ji} \Phi_i \begin{pmatrix} E_i^+ \\ E_i^- \end{pmatrix}. \end{aligned} \quad (4.24)$$

図 4.1 N 層の多層媒質

ここで, M_{ji} と Φ_i は以下のように表される.

$$M_{ji} = \frac{1}{t_{ji}} \begin{pmatrix} 1 & r_{ji} \\ r_{ji} & 1 \end{pmatrix} \quad (4.25)$$

$$\Phi_i = \begin{pmatrix} \phi_i^+ & 0 \\ 0 & \phi_i^- \end{pmatrix} \quad (4.26)$$

$$= \begin{pmatrix} \exp(ik_i \cos \theta_i d_i) & 0 \\ 0 & \exp(-ik_i \cos \theta_i d_i) \end{pmatrix} \quad (4.27)$$

$k_i \cos \theta_i$ は媒質 i 中における波数ベクトルの界面に垂直な成分, d_i は媒質 i の厚さである.

N 層目では反射方向に進む電磁波がない. これを考慮すると, N 層目の電場は以下のように表せる.

$$\begin{aligned} \begin{pmatrix} E_N^+ \\ 0 \end{pmatrix} &= M_{N(N-1)} \Phi_{N-1} \cdots \Phi_{i+1} M_{(i+1)i} \Phi_i M_{i(i-1)} \cdots \Phi_2 M_{21} \begin{pmatrix} E_1^+ \\ E_1^- \end{pmatrix} \\ &= T \begin{pmatrix} E_1^+ \\ E_1^- \end{pmatrix} \\ &= \begin{pmatrix} T_{11} & T_{12} \\ T_{21} & T_{22} \end{pmatrix} \begin{pmatrix} E_1^+ \\ E_1^- \end{pmatrix} \end{aligned} \quad (4.28)$$

ここで, T は 2×2 の正方行列であり, 各層の屈折率と厚さを用いて以下のように表される.

$$T = M_{N(N-1)} \Phi_{N-1} \cdots \Phi_{i+1} M_{(i+1)i} \Phi_i M_{i(i-1)} \cdots \Phi_2 M_{21} \quad (4.29)$$

式 (4.28) を解くことにより, 反射係数 r と透過係数 t を以下のように求めることができる.

$$r = \frac{E_1^-}{E_1^+} = -\frac{T_{21}}{T_{22}} \quad (4.30)$$

$$t = \frac{E_N^+}{E_1^+} = T_{11} - T_{12} \frac{T_{21}}{T_{22}} \quad (4.31)$$

反射率 R および透過率 T は式 (4.17), (4.18) により計算することができる.

4.4 設計方法

図 4.2(a) は, グラファイトを分散させた複合材料の概略図であり, PDMS をマトリックスとして使用した. グラファイト/PDMS の比誘電率の測定方法と測定データは, 付録 C.1 に記載した. 図 4.2(b) に, 理想金属基板 (反射率が 100%) 上に形成した 10 層 MLA の概要を示す. この金属基板の比誘電率は -10000 とした. 各層には自由空間に面するほうから順に番号付けをした. 層 i の厚さを d_i , MLA 全体の厚さを D と表す. 垂直入射を想定したため, 偏光依存性は生じない.

MLA の設計には, 実数値エンコーディング方式の GA を使用した [56]. GA を用いた設計では, 各層の厚さを均一に設定した. 各層のグラファイト含有率 f_i (ここで i は層番号であり, $i = 1 - 10$, 単位は wt%) を GA によって最適化した. f_i は, グラファイトがマトリックス内で均一に分散するよう, 0% – 10% (10% 制約と呼ぶ) または 0% – 15% (15% 制約と呼ぶ) に制限した. MLA の総厚さ D は, 0.1, 0.2, 0.3, 0.4 および 0.5 mm を検討した. したがって, 各層の厚さは $D/10$ mm である.

4.3 節で説明したフレネル方程式 / 転送行列法を用いて反射率 R を 1 GHz ごとに計算した.




図 4.2 MLA の概略図. (a) グラファイトと PDMS からなる薄膜. (b) 理想金属板の上に構成された 10 層 MLA. D は MLA の総厚さであり, d_i は i 層目の厚さを示す. z 軸は表面の法線方向として定義する.

基板として理想金属を使用したため、吸収率 $A(\text{dB})$ は以下の式を用いて計算した。

$$A = -10 \log_{10} R. \quad (4.32)$$

適合度関数 (F) は, ARF バンド (76 – 81 GHz) および W バンド (75 – 110 GHz) において 20 dB 以上の吸収率が得られるように, 以下の式で定義した。

$$F = \int_{75 \text{ GHz}}^{76 \text{ GHz}} \min(A(f), 20) df + \int_{76 \text{ GHz}}^{81 \text{ GHz}} 1000 \cdot \min(A(f), 20) df \\ + \int_{81 \text{ GHz}}^{110 \text{ GHz}} \min(A(f), 20) df. \quad (4.33)$$

この適合度関数は, 広帯域吸収を促進させつつ鋭い吸収ピークを抑制することを目的としたものである。鋭い吸収ピークを持つ個体を淘汰させるために, 上限付き吸収率 $\min(A(f), 20)$ を導入した。この $\min$ 演算子は, 指定された 2 つの値のうち小さい方を選択する。また, ARF バンド (76–81 GHz) での吸収ピークを確保するために, この範囲での吸収率に 1000 の重みを付けた。より単純な適合度関数 F を用いた設計結果は付録 C.2 に示されており, その場合は注目している帯域で 20 dB 以上の吸収率を示す MLA を必ず設計できるわけではなかった。このことから, 上限付き吸収率を用いる式 (4.33) が不可欠であることが示唆された。

GA を用いた MLA 設計は, 最も高い F が得られる各層のグラフィット含有率を最適化するために実施した。Distributed Evolutionary Algorithms in Python (DEAP) フレームワークを用い, 以下の条件で計算を行った [36]。

トーナメント選択サイズ	: 3
二点交叉確率	: 50% – 90%
突然変異確率	: 20% – 90%
集団サイズ	: 10000
世代数	: 200

各 MLA の総厚さ D に対して, 異なる擬似乱数を用いて 10 回の試行を行った。1.3.3 節で説明したように, 交叉確率と突然変異確率を変数として扱い, 評価効率を高めた (AGA)。

4.5 結果と考察

4.5.1 吸収スペクトル

図 4.3 に, 総厚さ $D = 0.1\text{--}0.5\text{ mm}$ の MLA の W バンドにおける吸収率を示す。実線は 15% 制約の下で設計された MLA の吸収率スペクトルを表し, 破線は 10% 制約の下で設計されたものを表している。総厚さ D が増加するにつれて, W バンド全体での吸収率が向上した。 $D = 0.2\text{ mm}$ の MLA (赤の実線) は, ARF バンド (76–81 GHz) で約 10 dB の吸収率を示したが, 20 dB 以上という要求を満たさなかった。一方, 総厚さ $D = 0.3\text{ mm}$ の MLA (青の実

線) は 20 dB を超えた. また, 総厚さ $D = 0.5$ mm の MLA (水色の実線) は, W バンド全域で 20 dB を超える吸収率を示した. 10% 制約の下でも, AGA で設計された MLA は同様の吸収性能を示した.

図 4.4 に, 15% 制約の下で設計されたグラファイト含有率のプロファイルを示す. 総厚さ $D = 0.1$ mm の MLA では, 全 10 層が最大含有率 15% を示し, MLA が均質であった. $D = 0.2$ mm および $D = 0.3$ mm の MLA では, 高いグラファイト含有率を持つ層が空気側に設計され, 他の層のグラファイト含有率は無視できるほど小さかった. これに対し, $D = 0.4$ mm および $D = 0.5$ mm の MLA では, 高いグラファイト含有率を持つ層が金属基板側に設計された.

図 4.5 に, 10% 制約の下で設計されたグラファイト含有率のプロファイルを示す. この場合も, 15% に制限された場合と同様の傾向が見られた.




図 4.3 総厚さ D が 0.1–0.5 mm の吸収体における吸収スペクトル. 実線はグラファイト含有率の上限が 15% に制限された場合を示し, 破線は 10% に制限された場合を示している.





図 4.4 異なる総厚さ D の MLA におけるグラファイト含有率プロファイル (15% 制約下) .


 図 4.5 異なる総厚さ D の MLA におけるグラファイト含有率プロファイル (10% 制約下) .

4.5.2 AGA で設計された狭帯域 MLA の簡略化

MLA を製造する際には, 層数の少ない構造が望ましい. ここでは, AGA によって設計された MLA の層数を減らしても吸収特性が損なわれないことを示す.

図 4.4(c) に示されているように, $D = 0.3 \text{ mm}$ の MLA では, 最外層 (第 1 層) および第 2 層のグラファイト含有率はそれぞれ約 15% および約 3% であった. これに対し, 第 3 層から第 10 層のグラファイト含有率はほぼゼロであった. この理由は, 図 4.6 (a) より, グラファイトを含まない層における電場が弱かったためである. ここでは, 計算された電場 E を入射電場 E_0 で正規化した結果をプロットしている. この構造をもとに, 空気側に接する最外層にグラファイトを含む層を配置し, その内側にスペーサー層を配置する 2 層構造の簡略化 MLA を設計した. 2 層の厚さを包括的に調査し, 適合度値を最大化する構造を決定した (詳細は付録 C.3.1 を参照のこと). その結果, この 2 層構造の MLA も高い性能を示し, その吸収率スペクトルを図 4.7 に赤の実線で示す. 簡略化した MLA の構造を図 4.7 内に挿入図として示した. また, AGA によって最適化された 10 層 MLA のスペクトルを比較のため破線で示した. 両者のスペクトルはほぼ一致しており, ARF バンドで 20 dB 以上の吸収率を達成するという目標を, 総厚さ 0.3 mm で達成した. 2 層 MLA の入射角度依存性は付録 C.4 に示した. 両偏光において, 入射角度 $\theta_1 = 0^\circ - 15^\circ$ で設計目標の吸収率 20 dB を概ね達成した.

狭帯域 MLA は, Salisbury screen の設計概念と類似している [1]. Salisbury Screen は, 吸




図 4.6 (a) 狭帯域 MLA ($D = 0.3 \text{ mm}$) および (b) 広帯域 MLA ($D = 0.5 \text{ mm}$) における正規化された電場分布.




図 4.7 吸収体の総厚さ $D = 0.3 \text{ mm}$ における元の設計と簡略化された構造による吸収スペクトルの比較（15% 制約下で設計）．簡略化された MLA の模式図を右上に示した．

収層として機能する第 1 層と、スペーサーとして使用される損失のない誘電体層で構成される 2 層構造である．損失のないスペーサー層の厚さ t は次式で与えられる．

$$t = \frac{\lambda}{4n} \quad (4.34)$$

ここで、 λ は真空中のピーク波長、 n は損失のない誘電体スペーサーの屈折率である．78 GHz における厚さ t は 0.570 mm である．一方で、簡略化した MLA のスペーサー層の厚さ d_2 は 0.264 mm であり、これは t と一致しない．理由は、吸収層が十分薄くないこと、および吸収層の比誘電率の実数部分が存在するためである [80, 81]．

他の文献で報告された狭帯域 ARF 吸収体の性能を表 4.1 に示す．これらは ARF バンド (76 – 81 GHz) をほとんどカバーしている．我々の MLA は、Kim らによる抵抗性正方形パッチ周波数選択表面 [68] の吸収率と同程度であり、それよりも薄い．一方で、Singh らによる吸収体 [82] はさらに薄い、十分な吸収率を達成していない．これらの吸収体はどちらも複雑な製造プロセスを必要とするメタサーフェスで構成されている．一方で、我々の MLA は表面パターンニングを必要とせず、従来の Salisbury screen よりも薄い．

4.5.3 AGA で設計された広帯域 MLA の簡略化

広帯域 MLA についても、狭帯域 MLA と同様に簡略化を行った．図 4.4 (d) および (e) を参照すると、広帯域 MLA では、AGA により設計された構造では、金属基板側に高いグラファイト含有率の層が設計され、空気側の最外層には低いグラファイト含有率の層が設計され、それら

表 4.1 ARF バンド向け吸収体の性能比較

Frequency range (GHz)	Absorptance (%)	Thickness (mm)	Method	Reference
75 – 82	> 99	0.5	Fabrication	[68]
75 – 80	> 80	0.126	Fabrication	[82]
76 – 81	> 99	0.3	Simulation	This work

の間にはグラファイト含有率が無視できるスペーサー層が挟まれていた。このグラファイト含有率の分布は、電場分布によって説明できる。総厚さ $D = 0.5 \text{ mm}$ の場合の電場分布を図 4.6 (b) に示す。金属基板付近では電場が高く、吸収層をここに設計することで電磁波を効率的に吸収できる。

狭帯域 MLA の設計と同様に、各層の厚さを検討した（詳細は付録 C.3.2 を参照）。その結果、高性能を示す 3 層構造の MLA を見出した。その吸収率スペクトルを図 4.8 に赤の実線で示した。比較のため、AGA を用いて最適化された 10 層 MLA のスペクトルを黒の破線で示した。総厚さ $D = 0.5 \text{ mm}$ に関して、簡略化された 3 層 MLA は、吸収特性がやや劣るものの、W バンドにおいて 20 dB 以上の吸収率を達成する目標を満たしている。また、最外層からグラファイトを除去した構造 ($f_1 = 0\%$) のスペクトルを青の実線で示した。このスペクトルは 20 dB の要求を満たしておらず、最外層には低い含有率でもグラファイトが必要であることを示している。よって、金属基板に隣接する吸収層および最外層の吸収層の双方の存在により、W バンド全体で吸収率が 20 dB 以上を達成する MLA の設計が可能であることが示された [83]。3 層 MLA の入射角度依存性は付録 C.4 に示した。両偏光において、入射角度 $\theta_1 = 0^\circ - 60^\circ$ で吸収率 10 dB を達成したことから、角度依存性は低い。

表 4.2 に、他の研究で報告された広帯域吸収体の性能を示す。これらの吸収体は W バンド全体をカバーしている。3D メタマテリアル [84, 85]、グラフェン周波数選択表面 [76]、および PMMA とグラフェンで構成された多層吸収体 [86] は、いずれもシミュレーションの結果のみが報告されており、実際に作製されていない。Wu らは、Electrohydrodynamics (EHD) 印刷法を用いた銀メッシュの吸収体を作製した [87]。この吸収体は本研究の MLA と同程度の薄さであるが、吸収率 (90% 以上) は本研究の MLA よりも低い。また、EHD 印刷の速度は小さいと推定されるため、大面積化に向いていない [88]。Zhang ら [69] が作製したグラフェンフォーム吸収体は厚みがあり、吸収率は本研究の MLA よりも低い。我々の吸収体は、他と比較して最も薄い ($D = 0.5 \text{ mm}$) にもかかわらず、吸収率が最も高く (99% 以上) になっている。さらに、簡便なプロセスで製作可能であり、大面積化に向いている。




図 4.8 吸収体の総厚さ $D = 0.5 \text{ mm}$ における元の設計と簡略化された構造による吸収スペクトルの比較 (15% 制約下で設計) . 簡略化された 3 層 MLA の模式図を右上に示した. 階段状のスペクトルは, PDMS の比誘電率が有効数字 2 桁で測定されたことに起因する.

表 4.2 広帯域吸収体の性能比較

Frequency range (GHz)	Absorbance (%)	Thickness (mm)	Method	Reference
38 – 142	> 90	1	Simulation	[84]
50 – 460	> 90	1	Simulation	[85]
73.5 – 110	> 90	0.526	Fabrication	[87]
75 – 110	> 90	1	Fabrication	[69]
39.2 – 200	> 95	0.74	Simulation	[76]
50 – 300	> 90	1	Simulation	[86]
75 – 110	> 99	0.5	Simulation	This work

4.6 結論

我々は, AGA を用いて目標の性能を持つ 2 種類の MLA を設計することに成功した. それぞれ, ARF バンドまたは W バンドにおいて吸収率 20 dB 以上を達成した. ARF バンドをカバーする狭帯域 MLA の必要な厚さは 0.3 mm であり, W バンドをカバーする広帯域 MLA の必要な厚さは 0.5 mm である. これらは他の研究で報告された吸収体の中において, 最も高水準に薄さと高吸収率を両立した. 最初に, AGA を用いた設計では, 10 層で構成された MLA を

検討した。しかし、実際の生産においては、より少ない層数を持つ MLA が望ましい。そのため、構造の簡略化を試みた結果、同等の性能を持ちながら層数の少ない MLA を発見した。本研究は、AGA が特定の条件下で最高の性能を持つ構造を設計するために使用できることを示している。我々の吸収体は、高トラフィックなレーダー応用において ADAS および自動運転技術の誤検出を減らすのに役立つと考えられる。

第 5 章

結論

本論文では、GA を中心とした最適化手法の有効性を多層円筒媒質の設計によって示し、AGA をクロッキング媒質の設計およびミリ波吸収体の設計に活用し、それぞれの性能を評価した。

第 1 章では序論として、光学・電磁波多層媒質の概要および本論文の目的を述べ、確率を含む最適化アルゴリズム (DL, BO, GA) の詳細を説明した。

第 2 章で GA の多層媒質設計における有効性を検証した。GA と AGA はいずれも進化が十分に収束し、安定した性能を示した。未知パラメータが少ない場合には GA が、未知パラメータが多い複雑なブラックボックス問題では AGA が特に有効であり、多層媒質の設計においても AGA の優位性が示唆された。一方、NN と AGA を組み合わせた手法は高速性に優れるものの、NN の予測誤差により設計性能が GA や AGA に劣った。また、BO は初期サンプル生成時の局所解への収束や試行間のばらつきが大きく、高性能な設計が得られない場合が多かった。

第 3 章では AGA を用いたクロッキング媒質の設計を実施した。可視光全域をカバーする広帯域クロックを設計し、対象物体の散乱断面積を 6% 以下に低減することに成功した。従来の TO と EMA に基づく解析設計を上回る性能を達成し、AGA がクロッキング設計において強力なツールであることを示した。ただし、今回の設計では比誘電率は波長分散がないと仮定した。また、吸収もないとした。今後の課題として、広帯域に低散乱な媒質を実現するには、波長分散と吸収の影響を考慮する必要がある。

第 4 章では、AGA を用いて ARF バンドおよび W バンドに対応する 2 種類の MLA を設計した結果、10 層で高吸収率を実現する構造を実現した。特に、層数を減らしても同等の性能を維持する設計を行い、ADAS や自動運転技術における誤検出の低減に貢献できる可能性を示した。

本論文では、GA が多層媒質設計において有効な手法であることを示し、多層円筒クロックおよびミリ波多層吸収体の設計を通じて、高性能な媒質の設計が可能であることを実証した。

謝辞

本研究を進めるにあたり、ご指導をいただいた梶川浩太郎 教授, 當麻真奈 准教授, OGUCHI MARIA VANESSA BALOIS 助教に感謝申し上げます。ミリ波吸収体のグラファイト/PDMS および PDMS の誘電率測定は、出光興産 次世代技術研究所の近藤氏, 南風盛氏に実施していただきました。研究室の先輩である Rahul Kumar 氏, HOANG Thi Thanh Tam 氏, 杉本陽祐氏, 板倉雄士氏には学生生活や研究に関するアドバイスを多くいただきました。また、研究室の同期である碓真一氏, 伊藤有輝氏, 並原慎之輔氏, および後輩の後藤匠氏, 弘世幹久氏, 堀江侃生氏, 吉川圭氏, Zhou Tong 氏をはじめ、多くの方々とディスカッションや情報共有を通じて、研究を円滑に進めることができたことに深く感謝いたします。

参考文献

- [1] R.L. Fante and M.T. McCormack. Reflection properties of the Salisbury screen. *IEEE Transactions on Antennas and Propagation*, Vol. 36, No. 10, pp. 1443–1454, 1988.
- [2] Ben-Xin Wang, Chongyang Xu, Guiyuan Duan, Wei Xu, and Fuwei Pi. Review of Broadband Metamaterial Absorbers: From Principles, Design Strategies, and Tunable Properties to Functional Applications. *Advanced Functional Materials*, Vol. 33, No. 14, p. 2213818, 2023. __eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/adfm.202213818>.
- [3] Peng Yu, Lucas V. Besteiro, Yongjun Huang, Jiang Wu, Lan Fu, Hark H. Tan, Chennupati Jagadish, Gary P. Wiederrecht, Alexander O. Govorov, and Zhiming Wang. Broadband Metamaterial Absorbers. *Advanced Optical Materials*, Vol. 7, No. 3, p. 1800995, 2019. __eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/adom.201800995>.
- [4] 山川宏. 最適設計ハンドブック：基礎・戦略・応用. 朝倉書店, 2003.
- [5] 染谷博司, 半田久志, 小坪成一. 確率的最適化の設計技術と適用技術. 電気学会論文誌C (電子・情報・システム部門誌), Vol. 132, No. 1, pp. 2–5, 2012.
- [6] 安田恵一郎, 熊谷渉. ブラックボックス最適化と応用. 計測と制御, Vol. 59, No. 12, pp. 914–917, 2020.
- [7] Leslie Pack Kaelbling, Michael L Littman, and Andrew W Moore. Reinforcement learning: A survey. *Journal of artificial intelligence research*, Vol. 4, pp. 237–285, 1996.
- [8] Oludare Isaac Abiodun, Aman Jantan, Abiodun Esther Omolara, Kemi Victoria Dada, Nachaat AbdElatif Mohamed, and Humaira Arshad. State-of-the-art in artificial neural network applications: A survey. *Heliyon*, Vol. 4, No. 11, November 2018. Publisher: Elsevier.
- [9] Bobak Shahriari, Kevin Swersky, Ziyu Wang, Ryan P. Adams, and Nando de Freitas. Taking the Human Out of the Loop: A Review of Bayesian Optimization. *Proceedings of the IEEE*, Vol. 104, No. 1, pp. 148–175, 2016.
- [10] Peter I. Frazier. A Tutorial on Bayesian Optimization, 2018. __eprint: 1807.02811.
- [11] Xilu Wang, Yaochu Jin, Sebastian Schmitt, and Markus Olhofer. Recent Advances

- in Bayesian Optimization. *ACM Comput. Surv.*, Vol. 55, No. 13s, July 2023. Place: New York, NY, USA Publisher: Association for Computing Machinery.
- [12] J. Kennedy and R. Eberhart. Particle swarm optimization. In *Proceedings of ICNN'95 - International Conference on Neural Networks*, Vol. 4, pp. 1942–1948 vol.4, 1995.
- [13] Dongshu Wang, Dapei Tan, and Lei Liu. Particle swarm optimization algorithm: an overview. *Soft Computing*, Vol. 22, No. 2, pp. 387–408, January 2018.
- [14] John H. Holland. Genetic Algorithms. *Scientific American*, Vol. 267, No. 1, pp. 66–73, 1992. Publisher: Scientific American, a division of Nature America, Inc.
- [15] Naoto Akashi, Mana Toma, and Kotaro Kajikawa. Design by neural network of concentric multilayered cylindrical metamaterials. *Applied Physics Express*, Vol. 13, No. 4, p. 042003, March 2020. Publisher: IOP Publishing.
- [16] John Peurifoy, Yichen Shen, Li Jing, Yi Yang, Fidel Cano-Renteria, Brendan G. DeLacy, John D. Joannopoulos, Max Tegmark, and Marin Soljačić. Nanophotonic particle simulation and inverse design using artificial neural networks. *Science Advances*, Vol. 4, No. 6, p. eaar4206, 2018. _eprint: <https://www.science.org/doi/pdf/10.1126/sciadv.aar4206>.
- [17] Iman Sajedian, Trevon Badloe, and Junsuk Rho. Optimisation of colour generation from dielectric nanostructures using reinforcement learning. *Opt. Express*, Vol. 27, No. 4, pp. 5874–5883, February 2019. Publisher: Optica Publishing Group.
- [18] Atsushi Sakurai, Kyohei Yada, Tetsushi Simomura, Shenghong Ju, Makoto Kashiwagi, Hideyuki Okada, Tadaaki Nagao, Koji Tsuda, and Junichiro Shiomi. Ultranarrow-Band Wavelength-Selective Thermal Emission with Aperiodic Multilayered Metamaterials Designed by Bayesian Optimization. *ACS Central Science*, Vol. 5, No. 2, pp. 319–326, February 2019. Publisher: American Chemical Society.
- [19] Zhenzhong Yu, Yijun Feng, Xiaofei Xu, Junming Zhao, and Tian Jiang. Optimized cylindrical invisibility cloak with minimum layers of non-magnetic isotropic materials. *Journal of Physics D: Applied Physics*, Vol. 44, No. 18, p. 185102, April 2011.
- [20] Ali Mirzaei, Andrey E. Miroshnichenko, Ilya V. Shadrivov, and Yuri S. Kivshar. All-Dielectric Multilayer Cylindrical Structures for Invisibility Cloaking. *Scientific Reports*, Vol. 5, No. 1, p. 9574, April 2015.
- [21] Jun Rong Ong, Hong Son Chu, Valerian Hongjie Chen, Alexander Yutong Zhu, and Patrice Genevet. Freestanding dielectric nanohole array metasurface for mid-infrared wavelength applications. *Opt. Lett.*, Vol. 42, No. 13, pp. 2639–2642, July 2017. Publisher: Optica Publishing Group.
- [22] Mahmoud M. R. Elsawy, Stéphane Lanteri, Régis Duvigneau, Gauthier Brière, Mohamed Sabry Mohamed, and Patrice Genevet. Global optimization of metasurface designs using statistical learning methods. *Scientific Reports*, Vol. 9, No. 1, p. 17918,

- November 2019.
- [23] Frank Rosenblatt. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, Vol. 65, No. 6, p. 386, 1958. Publisher: American Psychological Association.
 - [24] 斎藤康毅. Python で学ぶディープラーニングの理論と実装. ゼロから作る deep learning, No. [1]. オライリー・ジャパン, オーム社 (発売), 2016.
 - [25] Jasper Snoek, Hugo Larochelle, and Ryan P Adams. Practical Bayesian Optimization of Machine Learning Algorithms. In F. Pereira, C. J. Burges, L. Bottou, and K. Q. Weinberger, editors, *Advances in Neural Information Processing Systems*, Vol. 25. Curran Associates, Inc., 2012.
 - [26] Ziyu Wang, Frank Hutter, Masrour Zoghi, David Matheson, and Nando De Freitas. Bayesian optimization in a billion dimensions via random embeddings. *Journal of Artificial Intelligence Research*, Vol. 55, pp. 361–387, 2016.
 - [27] Ben Letham, Roberto Calandra, Akshara Rai, and Eytan Bakshy. Re-Examining Linear Embeddings for High-Dimensional Bayesian Optimization. In H. Larochelle, M. Ranzato, R. Hadsell, M. F. Balcan, and H. Lin, editors, *Advances in Neural Information Processing Systems*, Vol. 33, pp. 1546–1558. Curran Associates, Inc., 2020.
 - [28] David Eriksson, Michael Pearce, Jacob Gardner, Ryan D Turner, and Matthias Poloczek. Scalable Global Optimization via Local Bayesian Optimization. In H. Wallach, H. Larochelle, A. Beygelzimer, F. d’Alché-Buc, E. Fox, and R. Garnett, editors, *Advances in Neural Information Processing Systems*, Vol. 32. Curran Associates, Inc., 2019.
 - [29] David Eriksson and Martin Jankowiak. High-dimensional Bayesian optimization with sparse axis-aligned subspaces. In Cassio de Campos and Marloes H. Maathuis, editors, *Proceedings of the Thirty-Seventh Conference on Uncertainty in Artificial Intelligence*, Vol. 161 of *Proceedings of Machine Learning Research*, pp. 493–503. PMLR, July 2021.
 - [30] Leonard Papenmeier, Luigi Nardi, and Matthias Poloczek. Increasing the Scope as You Learn: Adaptive Bayesian Optimization in Nested Subspaces. In S. Koyejo, S. Mohamed, A. Agarwal, D. Belgrave, K. Cho, and A. Oh, editors, *Advances in Neural Information Processing Systems*, Vol. 35, pp. 11586–11601. Curran Associates, Inc., 2022.
 - [31] Mickaël Binois and Nathan Wycoff. A Survey on High-dimensional Gaussian Process Modeling with Application to Bayesian Optimization. *ACM Trans. Evol. Learn. Optim.*, Vol. 2, No. 2, August 2022. Place: New York, NY, USA Publisher: Association for Computing Machinery.
 - [32] Miguel González Duque, Richard Michael, Simon Bartels, Yevgen Zainchkovskyy,

- Søren Hauberg, and Wouter Boomsma. A survey and benchmark of high-dimensional Bayesian optimization of discrete sequences. *CoRR*, Vol. abs/2406.04739, , 2024.
- [33] 豊田秀樹. 基礎からのベイズ統計学：ハミルトニアンモンテカルロ法による実践的入門. 朝倉書店, 2015.
- [34] 持橋大地, 大羽成征, 講談社サイエンティフィク. ガウス過程と機械学習 = Gaussian process and machine learning. MLP 機械学習プロフェッショナルシリーズ. 講談社, 2019.
- [35] Melanie Mitchell, 伊庭斉志, 本堂直浩, 伊藤拓也, 丹羽竜哉, 高畠一哉, 野添敏秀. 遺伝的アルゴリズムの方法. 情報科学. 東京電機大学出版局, 1997.
- [36] Félix-Antoine Fortin, François-Michel De Rainville, Marc-André Gardner Gardner, Marc Parizeau, and Christian Gagné. DEAP: Evolutionary algorithms made easy. *The Journal of Machine Learning Research*, Vol. 13, No. 1, pp. 2171–2175, 2012. Publisher: JMLR. org.
- [37] Xueming Liu and Byoungcho Lee. Optimal design for ultra-broad-band amplifier. *Journal of Lightwave Technology*, Vol. 21, No. 12, pp. 3446–3455, 2003.
- [38] Muhammed Sirajul Huda Kalathingall, Suradeep Basak, and Jayeeta Mitra. Artificial neural network modeling and genetic algorithm optimization of process parameters in fluidized bed drying of green tea leaves. *Journal of Food Process Engineering*, Vol. 43, No. 1, p. e13128, 2020. __eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1111/jfpe.13128>.
- [39] Tomoya Momose, Mana Toma, and Kotaro Kajikawa. Ultrabroadband invisibility cloaking design of a concentric multilayered cylindrical metamaterial. *J. Opt. Soc. Am. B*, Vol. 41, No. 8, pp. 1815–1820, August 2024. Publisher: Optica Publishing Group.
- [40] Vladimir M. Shalaev. Optical negative-index metamaterials. *Nature Photonics*, Vol. 1, No. 1, pp. 41–48, January 2007.
- [41] Saman Jahani and Zubin Jacob. All-dielectric metamaterials. *Nature Nanotechnology*, Vol. 11, No. 1, pp. 23–36, January 2016.
- [42] Alexander Poddubny, Ivan Iorsh, Pavel Belov, and Yuri Kivshar. Hyperbolic metamaterials. *Nature Photonics*, Vol. 7, No. 12, pp. 948–957, December 2013.
- [43] Yongmin Liu and Xiang Zhang. Metamaterials: a new frontier of science and technology. *Chem. Soc. Rev.*, Vol. 40, No. 5, pp. 2494–2507, 2011. Publisher: The Royal Society of Chemistry.
- [44] Ulf Leonhardt. Optical Conformal Mapping. *Science*, Vol. 312, No. 5781, pp. 1777–1780, 2006. __eprint: <https://www.science.org/doi/pdf/10.1126/science.1126493>.
- [45] J. B. Pendry, D. Schurig, and D. R. Smith. Controlling Electromagnetic Fields.

- Science*, Vol. 312, No. 5781, pp. 1780–1782, 2006. _eprint: <https://www.science.org/doi/pdf/10.1126/science.1125907>.
- [46] Andrea Alù and Nader Engheta. Achieving transparency with plasmonic and meta-material coatings. *Phys. Rev. E*, Vol. 72, No. 1, p. 016623, July 2005. Publisher: American Physical Society.
- [47] Andrea Alù, David Rainwater, and Aaron Kerkhoff. Plasmonic cloaking of cylinders: finite length, oblique illumination and cross-polarization coupling. *New Journal of Physics*, Vol. 12, No. 10, p. 103028, October 2010.
- [48] Ali Mirzaei, Ilya V. Shadrivov, Andrey E. Miroshnichenko, and Yuri S. Kivshar. Cloaking and enhanced scattering of core-shell plasmonic nanowires. *Opt. Express*, Vol. 21, No. 9, pp. 10454–10459, May 2013. Publisher: Optica Publishing Group.
- [49] Mikhail V. Rybin, Dmitry S. Filonov, Pavel A. Belov, Yuri S. Kivshar, and Mikhail F. Limonov. Switching from Visibility to Invisibility via Fano Resonances: Theory and Experiment. *Scientific Reports*, Vol. 5, No. 1, p. 8774, March 2015.
- [50] Kyoung-Ho Kim, You-Shin No, Sehwan Chang, Jae-Hyuck Choi, and Hong-Gyu Park. Invisible Hyperbolic Metamaterial Nanotube at Visible Frequency. *Scientific Reports*, Vol. 5, No. 1, p. 16027, November 2015.
- [51] Rahul Kumar and Kotaro Kajikawa. Comparison of cylinder- and planar-effective medium approximations on calculation of scattering properties of cylindrical hyperbolic metamaterials. *J. Opt. Soc. Am. B*, Vol. 36, No. 3, pp. 559–564, March 2019. Publisher: Optica Publishing Group.
- [52] Rahul Kumar and Kotaro Kajikawa. Superscattering from cylindrical hyperbolic metamaterials in the visible region. *Opt. Express*, Vol. 28, No. 2, pp. 1507–1517, January 2020. Publisher: Optica Publishing Group.
- [53] Wenshan Cai, Uday K. Chettiar, Alexander V. Kildishev, and Vladimir M. Shalaev. Optical cloaking with metamaterials. *Nature Photonics*, Vol. 1, No. 4, pp. 224–227, April 2007.
- [54] Ying Huang, Yijun Feng, and Tian Jiang. Electromagnetic cloaking by layered structure of homogeneous isotropic materials. *Opt. Express*, Vol. 15, No. 18, pp. 11133–11141, September 2007. Publisher: Optica Publishing Group.
- [55] Min Yan, Zhichao Ruan, and Min Qiu. Cylindrical Invisibility Cloak with Simplified Material Parameters is Inherently Visible. *Phys. Rev. Lett.*, Vol. 99, No. 23, p. 233901, February 2007. Publisher: American Physical Society.
- [56] Sourabh Katoch, Sumit Singh Chauhan, and Vijay Kumar. A review on genetic algorithm: past, present, and future. *Multimedia Tools and Applications*, Vol. 80, No. 5, pp. 8091–8126, February 2021.
- [57] H. C. van de (Hendrik Christoffel) Hulst. *Light scattering by small particles*. Structure

- of matter series. Wiley, Chapman & Hall, 1957.
- [58] M. Kerker and E. Matijević. Scattering of Electromagnetic Waves from Concentric Infinite Cylinders. *J. Opt. Soc. Am.*, Vol. 51, No. 5, pp. 506–508, May 1961. Publisher: Optica Publishing Group.
 - [59] D. S. Bethune. Optical harmonic generation and mixing in multilayer media: analysis using optical transfer matrix techniques. *J. Opt. Soc. Am. B*, Vol. 6, No. 5, pp. 910–916, May 1989. Publisher: Optica Publishing Group.
 - [60] John E. Sipe and Robert W. Boyd. Nanocomposite Materials for Nonlinear Optics Based on Local Field Effects. In Vladimir M. Shalaev, editor, *Optical Properties of Nanostructured Random Media*, pp. 1–19. Springer Berlin Heidelberg, Berlin, Heidelberg, 2002.
 - [61] 梶川浩太郎. 先端機能材料の光学：光学薄膜とナノフォトニクス基礎を理解する. 物質・材料テキストシリーズ / 藤原毅夫, 藤森淳, 勝藤拓郎監修. 内田老鶴圃, 2016.
 - [62] Steven A. Cummer, Bogdan-Ioan Popa, David Schurig, David R. Smith, and John Pendry. Full-wave simulations of electromagnetic cloaking structures. *Phys. Rev. E*, Vol. 74, No. 3, p. 036621, September 2006. Publisher: American Physical Society.
 - [63] Jingbo Sun, Ji Zhou, and Lei Kang. Homogenous isotropic invisible cloak based on geometrical optics. *Opt. Express*, Vol. 16, No. 22, pp. 17768–17773, October 2008. Publisher: Optica Publishing Group.
 - [64] Tomoya Momose, Hirofumi Kondo, Masamitsu Haemori, and Kotaro Kajikawa. Design of thin multilayer absorbers of graphite/polymer composites for W-band millimeter waves. *Japanese Journal of Applied Physics*, Vol. 64, No. 2, p. 022003, February 2025. Publisher: IOP Publishing.
 - [65] Christian Waldschmidt, Juergen Hasch, and Wolfgang Menzel. Automotive Radar — From First Efforts to Future Systems. *IEEE Journal of Microwaves*, Vol. 1, No. 1, pp. 135–148, 2021.
 - [66] Mike Köhler, Jürgen Hasch, Hans Ludwig Blöcher, and Lorenz-Peter Schmidt. Feasibility of automotive radar at frequencies beyond 100 GHz. *International Journal of Microwave and Wireless Technologies*, Vol. 5, No. 1, pp. 49–54, 2013. Edition: 2012/12/21 Publisher: Cambridge University Press.
 - [67] Anupriya Choudhary, Srikanta Pal, and Gautam Sarkhel. Broadband millimeter-wave absorbers: a review. *International Journal of Microwave and Wireless Technologies*, Vol. 15, No. 2, pp. 347–363, 2023. Edition: 2022/02/15 Publisher: Cambridge University Press.
 - [68] Min-Sung Kim and Sung-Soo Kim. Design and Fabrication of 77-GHz Radar Absorbing Materials Using Frequency-Selective Surfaces for Autonomous Vehicles Application. *IEEE Microwave and Wireless Components Letters*, Vol. 29, No. 12, pp.

- 779–782, 2019.
- [69] Yi Zhang, Yi Huang, Tengfei Zhang, Huicong Chang, Peishuang Xiao, Honghui Chen, Zhiyu Huang, and Yongsheng Chen. Broadband and Tunable High-Performance Microwave Absorption of an Ultralight and Highly Compressible Graphene Foam. *Advanced Materials*, Vol. 27, No. 12, pp. 2049–2053, 2015. _eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/adma.201405788>.
 - [70] Jingbo Sun, Lingyun Liu, Guoyan Dong, and Ji Zhou. An extremely broad band metamaterial absorber based on destructive interference. *Opt. Express*, Vol. 19, No. 22, pp. 21155–21162, October 2011. Publisher: Optica Publishing Group.
 - [71] Muhammad Amin, Mohamed Farhat, and Hakan Bağci. An ultra-broadband multilayered graphene absorber. *Opt. Express*, Vol. 21, No. 24, pp. 29938–29948, February 2013. Publisher: Optica Publishing Group.
 - [72] Farshid Gharib Garakani, Gholamreza Moradi, and Ayaz Ghorbani. Ultra-broadband absorber based on multilayered graphene. *Opt. Continuum*, Vol. 2, No. 5, pp. 1158–1165, May 2023. Publisher: Optica Publishing Group.
 - [73] Gongjie Xu, Jun Zhang, Xiaofei Zang, Okihito Sugihara, Hongwei Zhao, and Bin Cai. 0.1 – 20 THz ultra-broadband perfect absorber via a flat multi-layer structure. *Opt. Express*, Vol. 24, No. 20, pp. 23177–23185, October 2016. Publisher: Optica Publishing Group.
 - [74] K. Batrakov, P. Kuzhir, S. Maksimenko, A. Paddubskaya, S. Voronovich, Ph Lambin, T. Kaplas, and Yu Svirko. Flexible transparent graphene/polymer multilayers for efficient electromagnetic field absorption. *Scientific Reports*, Vol. 4, No. 1, p. 7191, November 2014.
 - [75] K. Batrakov, P. Kuzhir, S. Maksimenko, N. Volynets, S. Voronovich, A. Paddubskaya, G. Valusis, T. Kaplas, Yu. Svirko, and Ph. Lambin. Enhanced microwave-to-terahertz absorption in graphene. *Applied Physics Letters*, Vol. 108, No. 12, p. 123101, March 2016.
 - [76] Dong-Ke Zhu, Yong-Sheng Li, Wen-Yan Yin, and Er-Ping Li. A transparent broadband absorber based on graphene. In *2016 Asia-Pacific International Symposium on Electromagnetic Compatibility (APEMC)*, Vol. 01, pp. 1025–1027, 2016.
 - [77] Shiju Liu, Zhimin Ye, Ruiyang Tan, Mengqi Han, Haiyan Zhuang, and Ping Chen. Genetic algorithm-enabled on-demand co-design of optically transparent metamaterial for multispectral stealth applications. *Opt. Express*, Vol. 32, No. 18, pp. 30969–30981, August 2024. Publisher: Optica Publishing Group.
 - [78] Ye Han, Wenquan Che, Christos Christopoulos, Ying Xiong, and Yumei Chang. A Fast and Efficient Design Method for Circuit Analog Absorbers Consisting of Resistive Square-Loop Arrays. *IEEE Transactions on Electromagnetic Compatibility*, Vol. 58,

- No. 3, pp. 747–757, 2016.
- [79] S. Chakravarty, R. Mittra, and N.R. Williams. On the application of the microgenetic algorithm to the design of broad-band microwave absorbers comprising frequency-selective surfaces embedded in multilayered dielectric media. *IEEE Transactions on Microwave Theory and Techniques*, Vol. 49, No. 6, pp. 1050–1059, 2001.
- [80] P.G. Lederer. Modelling of practical Salisbury screen absorbers. In *IEE Colloquium on Low Profile Absorbers and Scatterers*, pp. 1/1–1/4, 1992.
- [81] Jinbong Kim. Design of Salisbury screen absorbers using dielectric lossy sheets. In *2011 IEEE International Conference on Microwave Technology & Computational Electromagnetics*, pp. 17–18, 2011.
- [82] Pramod K. Singh, Konstantin A. Korolev, Mohammed N. Afsar, and Sameer Sonkusale. Single and dual band 77/95/110 GHz metamaterial absorbers on flexible polyimide substrate. *Applied Physics Letters*, Vol. 99, No. 26, p. 264101, December 2011.
- [83] Feifei Li, Ping Chen, Yin Poo, and Rui-Xin Wu. Achieving Perfect Absorption by the Combination of Dallenbach Layer and Salisbury Screen. In *2018 Asia-Pacific Microwave Conference (APMC)*, pp. 1507–1509, 2018.
- [84] Xinyan Ling, Zhongyin Xiao, Xiaoxia Zheng, Jingyao Tang, and Kaikai Xu. Ultra-broadband metamaterial absorber based on the structure of resistive films. *Journal of Electromagnetic Waves and applications*, Vol. 30, No. 17, pp. 2325–2333, 2016. Publisher: Taylor & Francis.
- [85] Alireza Vahidi, Hamid Rajabalipanah, Ali Abdolali, and Ahmad Cheldavi. A honeycomb-like three-dimensional metamaterial absorber via super-wideband and wide-angle performances at millimeter wave and low THz frequencies. *Applied Physics A*, Vol. 124, No. 4, p. 337, March 2018.
- [86] D. Mencarelli, L. Pierantoni, M. Stocchi, and S. Bellucci. Efficient and versatile graphene-based multilayers for EM field absorption. *Applied Physics Letters*, Vol. 109, No. 9, p. 093103, August 2016.
- [87] Yanghui Wu, Chen Fu, Songsong Qian, Zhiyuan Zong, Xingyi Wu, Yutao Yue, and Wenhua Gu. Flexible and Transparent W-Band Absorber Fabricated by EHD Printing Technology. *IEEE Antennas and Wireless Propagation Letters*, Vol. 19, No. 8, pp. 1345–1349, 2020.
- [88] Yanghui Wu, Yuqiang Deng, Junjie Wang, Zhiyuan Zong, Xue Chen, and Wenhua Gu. THz Broadband Absorber Fabricated by EHD Printing Technology With High Error Tolerance. *IEEE Transactions on Terahertz Science and Technology*, Vol. 9, No. 6, pp. 637–642, 2019.
- [89] D.K. Ghodgaonkar, V.V. Varadan, and V.K. Varadan. Free-space measurement of

complex permittivity and complex permeability of magnetic materials at microwave frequencies. *IEEE Transactions on Instrumentation and Measurement*, Vol. 39, No. 2, pp. 387–394, 1990.

付 録 A

遺伝的アルゴリズムの有効性

A.1 BO を用いた NN のハイパーパラメータ最適化

A.1.1 概要

8 層円筒クロックにおいて, 内側層の比誘電率 $\varepsilon_A^1, \varepsilon_B^1$ と外側層の比誘電率 $\varepsilon_A^4, \varepsilon_B^4$ の計 4 個を入力パラメータ, 波長 400 nm~700 nm における散乱断面積 SCS を出力パラメータとする NN を構築した. NN の訓練を高速に実行するために, GPU(NVIDIA Quadro RTX 5000) を用いた. NN に入出力パラメータの関係を学習させる際には, 最適なハイパーパラメータを選ぶ必要があり, これを解決するために BO を用いた.

A.1.2 NN 構築のためのデータセット作成

コアの比誘電率を $\varepsilon_0 = 9$, コアの半径を $r_0 = 500$ nm, 厚さ 62.5 nm のシェルが 8 層, 最外殻までの半径を $r_8 = 1000$ nm とした. 偏光は TE 偏光とした. 散乱断面積 SCS を計算する波長を 400 nm~700 nm とし, 1 nm 毎に計算した. 内側のシェル比誘電率 $\varepsilon_A^1, \varepsilon_B^1$ と外側のシェル比誘電率 $\varepsilon_A^4, \varepsilon_B^4$ の値を以下のように取ることで, データセットのサイズは $41^2 \times 11^2 = 203,401$ 個となった.

$\varepsilon_A^1, \varepsilon_A^4$: 41 通り

間隔 : 0.35

(1.00, 1.35, 1.70, ..., 14.30, 14.65, 15.00)

$\varepsilon_B^1, \varepsilon_B^4$: 11 通り

間隔 : 0.1

(0.001, 0.1, 0.2, 0.3, ..., 0.8, 0.9, 1.0)

$\varepsilon_A^2, \varepsilon_B^2, \varepsilon_A^3, \varepsilon_B^3$ は線形に変化させるために式 (3.59), (3.60) で計算した.

4 入力パラメータの全組み合わせのデータセットを作成し, Python の数値計算ライブラリ

「NumPy」の random モジュール「Generator.shuffle」を用いて、データをシャッフルした。シャッフルされたデータセットを訓練用 (95%), 検証用 (4%), テスト用 (1%) の 3 つに分割した。データサイズはそれぞれ訓練用が 193,230 個, 検証用が 8,136 個, テスト用が 2,035 個となった。

A.1.3 ベイズ最適化の実行

BO には Python のオープンソースライブラリ「GPyOpt」を使用した。探索空間の大きさを A , 探索数を B とした場合, その比率は $(\frac{B}{A} \times 100) \%$ と表される。NN の構築には, Google が開発しオープンソースで公開している, 機械学習に用いるためのソフトウェアライブラリ「TensorFlow」を用いた。TensorFlow には early stopping という機能がある。これは, 過学習を避けるための機能であり, 引数を「patience = x », 「monitor = validation loss」とすることで, 検証誤差が x エポックの間で最小値を更新しなかったら訓練を終了する, というものである。これを用いることで, エポック数を探索候補から外すことができた。活性化関数は SoftPlus に固定し, 探索候補から外した。したがって, 以下のようにハイパーパラメータの取りうる選択肢を決定した。

隠れ層数 H : 14 通り

(2, 3, 4, ..., 13, 14, 15)

ノード数 N : 16 通り

(50, 100, 200, 300, ..., 1300, 1400, 1500)

オプティマイザ: 4 通り

(RMSprop, Adam, Adamax, Nadam)

バッチサイズ: 5 通り

(100, 200, 400, 800, 1600)

隠れ層数 H やノード数 N は図 A.1 に示した。探索空間の大きさは $14 \times 16 \times 4 \times 5 = 4,480$ である。もし, early stopping が起きなくてもエポック数が 1000 に到達したら訓練を終了させるようにした。そして, BO の初期サンプリング数は 30, モデル更新回数は 60 にした。したがって, 探索比率は 2% である。BO の獲得関数として, 信頼性下限関数 LCB(Lower Confidence Bound) を用いた。LCB は 1.3.2.3 節の式 (1.34) で示した。

NN の損失関数を平均二乗誤差 (MSE) とし, BO でテストデータの MSE が最小になるようなハイパーパラメータの組み合わせを探索した。結果を理解しやすくするために平均二乗誤差の平方根 (RMSE) も利用した。MSE は式 (A.1), RMSE は式 (A.2) で表される。

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (\text{A.1})$$




図 A.1 NN の構造

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (A.2)$$

このとき, n はデータ数, y_i は正解値, $\hat{y}_i$ は予測値である. また, 構築された NN が予測するスペクトルと正解スペクトルの誤差を評価するために, 平均絶対パーセント誤差 (MAPE) を用いた. MAPE は式 (A.3) で表される.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (A.3)$$

BO を実行した結果を示す. この最適化には 63 時間を要した. early stopping を採用したため, 300 エポックで終了していた. 表 A.1 のように, 訓練 RMSE は 100.7, 検証 RMSE は 108.8, テスト RMSE は 106.0 だった. これら RMSE は個々のデータの RMSE の平均値である. ハイパーパラメータは表 A.2 のように最適化された. テスト RMSE が 106.0 であり, これを 100 以下にしたいと考えたため, early stopping が効果的に働いたかを調べた.

表 A.1 early stopping 採用時の各 RMSE

データ	RMSE
訓練	100.7
検証	108.8
テスト	106.0

表 A.2 early stopping 採用時の最適化されたハイパーパラメータ

隠れ層数	ノード数	オプティマイザ	バッチサイズ
8	1100	Adamax	200

図 A.2 より, early stopping を用いた場合, 訓練が強制終了した 300 エポック付近に, 検証 RMSE の傾きがまだ存在していることがわかる. 今回, early stopping の設定「patience」を 20, 「monitor」を validation loss としたため, 20 エポック以内で検証誤差が最小値を更新せずに学習が終了してしまった. このことから, もっとエポック数を増やせば検証 RMSE は減少することが予測できる. 図 A.2 を見てわかるように, 検証 RMSE の曲線がギザギザしており, このような場合は early stopping が有効でない可能性があることがわかった.

次に, 上記の結果に基づいて early stopping を使用せずに 1000 エポックで訓練を行った. このとき, 表 A.2 の最適なハイパーパラメータを用いた.

結果として図 A.3 より, 訓練が終了する 1000 エポック付近での検証誤差の傾きはほとんどみられなかったため, 学習不足は解消されているといえる. 表 A.3 より, テスト RMSE は 96.0 であった. これら RMSE は個々のデータの RMSE の平均値である. テスト RMSE のヒストグラムを図 A.4 に示す.




図 A.2 early stopping 採用時の各 RMSE の推移




図 A.3 early stopping なしの各 RMSE

表 A.3 1000 エポック終了時の各 RMSE

データ	RMSE
訓練	84.8
検証	99.3
テスト	96.0




図 A.4 テスト RMSE のヒストグラム

個々のスペクトルの RMSE の大きさによってランク付けをおこなうことで、最良予測 (図 A.5)、最悪予測 (図 A.6)、平均予測 (図 A.7) を特定した。表 A.4 のように最良予測の MAPE は 0.17%, 最悪予測の MAPE は 3.3%, 平均予測の MAPE は 1.9% だった。図 A.5 に示す最良予測では、NN による予測スペクトルが正解データとほぼ一致している。一方、図 A.6 に示す最悪予測においても、NN は正解スペクトルのおおよその形状を捉えている。特に、ピーキーなスペクトルを完全に予測できた場合、過学習の可能性が懸念されるため、この程度の予測誤差は許容範囲内であると判断できる。

表 A.4 各 MAPE

予測結果	MAPE(%)
最良	0.17
最悪	3.3
平均	1.9




図 A.5 最良予測




図 A.6 最悪予測




図 A.7 平均予測

A.2 未知パラメータが 4 個の場合




図 A.8 未知パラメータが 4 個の AGA における進化過程. 10 回試行し, それらを 10 色のデータで示した. (a) 各世代の計算時間. (b) 各世代の最良解で計算された平均散乱断面積.




図 A.9 未知パラメータが 4 個の GA における進化過程. 10 回試行し, それらを 10 色のデータで示した. (a) 各世代の計算時間. (b) 各世代の最良解で計算された平均散乱断面積.




図 A.10 未知パラメータが 4 個の NN+AGA における進化過程. 10 回試行し, それらを 10 色のデータで示した. (a) 各世代の計算時間. (b) 各世代の最良解で計算された平均散乱断面積.




図 A.11 未知パラメータが 4 個の BO における最適化過程. 10 回試行し, それらを 10 色のデータで示した. (a) 各イテレーションの計算時間. (b) 各イテレーションの最良解で計算された平均散乱断面積.

A.3 未知パラメータが 6 個の場合




図 A.12 未知パラメータが 6 個の AGA における進化過程. 10 回試行し, それらを 10 色のデータで示した. (a) 各世代の計算時間. (b) 各世代の最良解で計算された平均散乱断面積.




図 A.13 未知パラメータが 6 個の GA における進化過程. 10 回試行し, それらを 10 色のデータで示した. (a) 各世代の計算時間. (b) 各世代の最良解で計算された平均散乱断面積.




図 A.14 未知パラメータが 6 個の BO における最適化過程. 10 回試行し, それらを 10 色のデータで示した. (a) 各イテレーションの計算時間. (b) 各イテレーションの最良解で計算された平均散乱断面積.

A.4 未知パラメータが 8 個の場合




図 A.15 未知パラメータが 8 個の AGA における進化過程. 10 回試行し, それらを 10 色のデータで示した. (a) 各世代の計算時間. (b) 各世代の最良解で計算された平均散乱断面積.




図 A.16 未知パラメータが 8 個の GA における進化過程. 10 回試行し, それらを 10 色のデータで示した. (a) 各世代の計算時間. (b) 各世代の最良解で計算された平均散乱断面積.




図 A.17 未知パラメータが 8 個の BO における最適化過程. 10 回試行し, それらを 10 色のデータで示した. (a) 各イテレーションの計算時間. (b) 各イテレーションの最良解で計算された平均散乱断面積.

A.5 未知パラメータが 16 個の場合




図 A.18 未知パラメータが 16 個の AGA における進化過程. 10 回試行し, 10 色のデータで示した. (a) 各世代の計算時間. (b) 各世代の最良解で計算された平均散乱断面積.




図 A.19 未知パラメータが 16 個の GA における進化過程. 10 回試行し, それらを 10 色のデータで示した. (a) 各世代の計算時間. (b) 各世代の最良解で計算された平均散乱断面積.




図 A.20 未知パラメータが 16 個の BO における最適化過程. 10 回試行し, それらを 10 色のデータで示した. (a) 各イテレーションの計算時間. (b) 各イテレーションの最良解で計算された平均散乱断面積.

付 録 B

広帯域な光学クロークの設計

B.1 Model II の設計結果

本文の 3.5 節では Model I ($\varepsilon_A^i < \varepsilon_B^i$) の CM について議論した. ここでは, AGA によって最適化された Model II ($\varepsilon_A^i > \varepsilon_B^i$) の CM に関する SCS スペクトル, CI, および比誘電率を示す. 図 B.1 において, Model I の 26 層および 32 層 CM の SCS スペクトルを実線で示した. 一方, Model II のスペクトルは破線で示した. また, 対象物体のみのスペクトルは黒の実線で示した. 線形スケールでは両 Model のスペクトルが類似していたため, 縦軸は対数スケールで表示した. 両 Model 共に, 顕著に低い散乱を示した.




図 B.1 Model I (実線) と Model II (破線) の 26 層および 32 層 CM の SCS スペクトル (C_{sca}). 対象物体のみのスペクトルは黒の実線で示されている.

図 B.2(a) および B.2(b) には, Model II の 26 層および 32 層 CM の ε_A および ε_B を, それぞれ円筒中心からの距離 r の関数として示した. T/E によって計算された比誘電率は, 黒の実線でプロットした.

図 B.3 には, AGA によって最適化された Model II の CI を紫色の四角形で示した. AGA は, 比誘電率の範囲を $\varepsilon_A = 1\text{-}30$ および $\varepsilon_B = 0\text{-}1$ として実施した. 比較のため, Model I の CI もプロットした. これらは本文中の図 3.7 に示されたものと同一である. Model I と Model II の CM における CI の差異は小さい.

図 B.4(a) および B.4(b) には, Model II の 26 層 CM における ε_r および ε_θ を, それぞれ円筒中心からの距離 r の関数としてプロットした. AGA は, 比誘電率の範囲を $\varepsilon_A = 1\text{-}30$ および $\varepsilon_B = 0\text{-}1$ として実施した. TO および Corrected TO で計算された比誘電率もプロットした. また, 図 B.4(c) および B.4(d) には, Model II の 32 層 CM における ε_r および ε_θ をそれぞれプロットした.




図 B.2 Model II ($\varepsilon_A^i > \varepsilon_B^i$) の (a) ε_A および (b) ε_B .




図 B.3 Model II ($\varepsilon_A^i > \varepsilon_B^i$) における CI (紫色の四角形で表示) . 比較のため, Model I ($\varepsilon_A^i < \varepsilon_B^i$) の CI もプロットした.




図 B.4 (a) および (b): Model II の 26 層 CM における ε_r および ε_θ を, 中心からの距離 r の関数としてプロットしたもの. AGA は $\varepsilon_A = 1-30$ および $\varepsilon_B = 0-1$ の範囲で比誘電率を最適化した. (c) および (d): Model II の 32 層 CM における ε_r および ε_θ .

B.2 対象物体の比誘電率を変えた場合のクロッキング指数

対象物体の異なる比誘電率 ϵ_T に対する CI を図 B.5 に示した. クローキング媒質は, 対象物体の比誘電率 $\epsilon_T = 9$ に対して AGA で最適化された 26 層 CM である. CI は, 対象物体の比誘電率 ϵ_T が異なってもほとんど変化しなかった. これにより光が対象物体を迂回し, 対象物体内部にはほとんど進入しないことが示された.




図 B.5 異なる比誘電率 ϵ_T を持つ対象物体に対する CI.

B.3 Model I における 8 層, 12 層, 16 層, 20 層, 32 層 CM の異方性誘電率

図 B.6 に, 本文の 3.6 節で示された 26 層 CM 以外の Model I の CM について, 設計された ϵ_r および ϵ_θ を示す. それらは円筒中心からの半径距離 r の関数としてプロットされている. 比誘電率の範囲を $\epsilon_A = 0 - 1$, および $\epsilon_B = 1 - 30$ として, AGA による設計を実行した. また, TO および corrected TO で計算された比誘電率もプロットした. Region II は緑色の背景で示した.




図 B.6 Model I における 8 層, 12 層, 16 層, 20 層, および 32 層 CM に対して AGA で設計された ε_r および ε_θ . 8 層 CM の ε_r および ε_θ をそれぞれ (a) および (b) に示した. 12 層 CM については (c) および (d), 16 層 CM については (e) および (f), 20 層 CM については (g) および (h), 32 層 CM については (i) および (j) に示した. また, TO および corrected TO で計算された値もプロットした.

付 録 C

ミリ波吸収体の設計

C.1 試料の作製方法・比誘電率の測定方法と測定データ

グラファイト/PDMS 薄膜および PDMS 薄膜は以下の手順で作製した。炭素繊維 (XN-100-25M, 日本グラファイトファイバー株式会社) と PDMS の主剤 (SILPOT™ 184 Silicone Elastomer Base, Dow Toray Co., Ltd.) を 1:9 の比率で自転公転式ミキサー (ARE-310, 株式会社シンキー) を用い, 2000 rpm で 2 分間混合した。その後, 硬化剤を加え, 再び 2000 rpm で 2 分間攪拌した後, 同じ速度で 2 分間の脱泡工程を行った。脱泡した混合物を 10 cm × 10 cm のアルミニウム型に注ぎ, ホットプレート上で 100 °C で 40 分間加熱した。硬化後, サンプルをアルミニウム型から取り外した。この薄膜の厚さは 0.38 mm であった。

グラファイト/PDMS 薄膜および PDMS 薄膜の比誘電率は, 自由空間法を用いて PNA ネットワークアナライザー (N5227A, Keysight Technologies) で測定した [89]。PDMS の測定された比誘電率を図 C.1(a) に示し, 10% のグラファイト含有率を持つグラファイト/PDMS 複合材料の比誘電率を図 C.1(b) に示す。図 C.1(c) および図 C.1(d) に示すグラファイト/PDMS 複合材料 (含有率 15%) の比誘電率およびグラファイトの比誘電率 ε_g は, 以下の並列コンデンサモデルの式を用いて計算した [60]。

$$\frac{f_g/\rho_g}{f_g/\rho_g + (1 - f_g)/\rho_P} \varepsilon_g + \frac{(1 - f_g)/\rho_P}{f_g/\rho_g + (1 - f_g)/\rho_P} \varepsilon_P = \varepsilon_c. \quad (C.1)$$

ここで, ε_P と ε_c はそれぞれ PDMS と複合材料の比誘電率, f_g はグラファイト含有率を表す。また, ρ_g と ρ_P は, それぞれグラファイト ($\rho_g = 2.22$) および PDMS ($\rho_P = 1.11$) の密度である。

C.2 異なる適合度関数で設計した MLA

20 dB を超える吸収率を達成することを目標に, 3 種類の適合度関数 F_a , F_b , および F_c を用いて MLA を設計した。 F_a は, W バンドにおける吸収率 A の単純な積分として定義した。 F_b は積分範囲を 3 つの部分に分割し, 76 – 81 GHz の自動車レーダー周波数帯域 (ARF バンド) 内の吸収率を過大評価するため, この範囲の吸収率に 1000 倍の係数を掛けた。 F_c は F_b




図 C.1 各材料の比誘電率. (a) PDMS, (b) グラファイト/PDMS (含有率 10%), (c) グラファイト/PDMS (含有率 15%), (d) グラファイトの比誘電率スペクトル. (c) および (d) のスペクトルは, グラファイト/PDMS (含有率 10%) および PDMS の測定された比誘電率を用いて計算した.

の設計概念を基に構築され, 上限付き吸収率 $\min(A(f), 20)$ を導入することで, 狭帯域で鋭い吸収率スペクトルを持つ個体を過小評価し, 淘汰させた. ここで, $\min$ 演算子は 2 つの入力値のうち小さい方を選択した.

$$F_a = \int_{75 \text{ GHz}}^{110 \text{ GHz}} A(f) df, \quad (\text{C.2})$$


$$F_b = \int_{75 \text{ GHz}}^{76 \text{ GHz}} A(f) df + \int_{76 \text{ GHz}}^{81 \text{ GHz}} 1000 \cdot A(f) df + \int_{81 \text{ GHz}}^{110 \text{ GHz}} A(f) df, \quad (\text{C.3})$$

$$F_c = \int_{75 \text{ GHz}}^{76 \text{ GHz}} \min(A(f), 20) df + \int_{76 \text{ GHz}}^{81 \text{ GHz}} 1000 \cdot \min(A(f), 20) df + \int_{81 \text{ GHz}}^{110 \text{ GHz}} \min(A(f), 20) df. \quad (\text{C.4})$$

表 C.1 に, 3 種類の適合度関数を用いて設計された MLA の吸収率スペクトルを示す. 各総厚さ D と適合度関数について, 10 回の試行を行い, その結果をプロットした. 適合度関数 F_a を用いた場合, 76 – 81 GHz のレーダーバンド向けの狭帯域 MLA も, W バンド全域をカバーする広帯域 MLA も設計することができなかった. F_b を用いた場合, 狭帯域 MLA は厚さ

$D = 0.4$ mm および 0.5 mm において設計することができた. 広帯域 MLA も $D = 0.5$ mm で設計できたが, 試行に使用された疑似乱数によっては失敗した. 最後に, F_c を用いた場合, 狭帯域 MLA は $D = 0.3, 0.4$, および 0.5 mm で設計され, 広帯域 MLA は $D = 0.5$ mm においてすべての試行で必ず設計できた. したがって, F_c は狭帯域 MLA および広帯域 MLA を設計するために最も効率的であることが示され, この関数を本文の 4.4 節で採用した.

表 C.1 異なる適合度関数を使用して設計された MLA の吸収率スペクトル



C.3 MLA の簡略化

C.3.1 狭帯域 MLA

10 層の MLA ($D = 0.3 \text{ mm}$, ARF バンドをカバー) を 2 層の MLA に簡略化した. 模式図を図 C.2(b) に挿入図として示した. 本文の 4.5.1 節の図 4.4(c) の結果に基づき, $f_1 = 15\%$ および $f_2 = 0\%$ と設定した. 図 C.2(a) に, ARF バンド全体で吸収率が 20 dB 以上 (以下「20+ dB」と記載) の領域を黄色で示した. 吸収率が 10+ dB 以上の領域は灰色で示し, いずれの条件も満たさない領域は濃紺色で示した. 白の破線は総厚さ ($D = d_1 + d_2$) が 0.3 mmであることを示している. 黄色の領域かつ $D = 0.3 \text{ mm}$ を満たす唯一の点は点 (i) であり, その許容度は高くない. $D = 0.3 \text{ mm}$ の線上の各点における吸収率スペクトルを図 C.2(b) に示した. 点 (i) は ARF バンドをカバーしているが, 他の点はカバーしていない. 点 (i) の吸収スペクトルを本文の 4.5.2 節の図 4.7 に赤の実線で示した.




図 C.2 (a) ARF バンド全体で吸収率が 20+ dB を示す領域を黄色で, 10+ dB を示す領域を灰色で, それぞれ d_1 および d_2 の関数として示した. 白の破線は総厚さ D が 0.3 mmであることを示す. (b) $D = 0.3 \text{ mm}$ における点 (i), (ii), (iii) の吸収率スペクトル. 点 (i) は ARF バンドをカバーしているが, 他の点はカバーしていない.

C.3.2 広帯域 MLA

$D = 0.5 \text{ mm}$ で W バンドをカバーする 10 層 MLA を 3 層 MLA に簡略化した. 模式図を図 C.3(b) に挿入図として示した. 本文の 4.5.1 節の図 4.4(e) の結果に基づき, $f_1 = 1\%$, $f_2 = 0\%$, $f_3 = 15\%$ と設定した. 図 C.3(a) では, d_2 および d_3 の関数として, W バンド全体で吸収率が $20+ \text{ dB}$ を示す領域を黄色で, $10+ \text{ dB}$ を示す領域を灰色で, それ以外を濃紺色で示した. 総厚さ ($D = d_1 + d_2 + d_3$) は 0.5 mm に設定した. 黄色の領域は比較的広く, 膜厚の誤差がある程度許容されることを示している. 図 C.3(b) では, 黄色の領域内の点 (i) および (ii), 黄色以外の領域内の点 (iii) および (iv) における吸収率スペクトルを示した. 黄色の領域以外では, ある周波数で吸収率が $20+ \text{ dB}$ を示しても, W バンド全体で 20 dB 以上を達成することはできなかった. 点 (i) の吸収スペクトルを本文の図 4.8 に赤の実線で示した.




図 C.3 (a) W バンド全体で吸収率が $20+ \text{ dB}$ を示す領域を黄色で, $10+ \text{ dB}$ を示す領域を灰色で, それぞれ d_2 および d_3 の関数として示した. 総厚さ D は 0.5 mm に設定され, 固定値である. (b) 点 (i), (ii), (iii), (iv) における吸収率スペクトル. 点 (i) および点 (ii) は W バンドをカバーしているが, 他の点はカバーしていない.

C.4 簡略化した MLA の入射角度依存性

4.5.2 節の図 4.7 に赤の実線で示した簡略化された 2 層狭帯域 MLA に関して, 吸収率スペクトルの入射角度依存性を計算した. s-偏光の結果を図 C.4 に, p-偏光の結果を図 C.5 に示す.

入射角度 θ_1 は 0° , 15° , 30° , 45° , 60° , および 75° の 6 通りである. 図 C.4 の s-偏光では, θ_1 が大きくなるにつれて, 全周波数において吸収率が一貫して低下した. 一方, 図 C.5 の p-偏光では, θ_1 の増加に伴い吸収ピークが高周波数側に移動し, 20 dB 以上の吸収率を示す周波数領域が広がった. 特に, $\theta_1 = 45^\circ$ の場合, 93 GHz 付近で顕著な吸収ピークを示した. さらに, $\theta_1 = 45^\circ$ を超える場合には, 吸収ピークが高周波数側へ移動するとともに, 全体的な吸収率が低下する傾向が見られた. どちらの偏光においても, $\theta_1 = 15^\circ$ までであれば設計目標の吸収率 20 dB を概ね達成した.

同様に, 4.5.3 節の図 4.8 に赤の実線で示した簡略化された 3 層広帯域 MLA に関して, 吸収率スペクトルの入射角度依存性を計算した. s-偏光の結果を図 C.6 に, p-偏光の結果を図 C.7 に示す. 図 C.6 の s-偏光では, θ_1 が大きくなるにつれて, 狭帯域 MLA の場合と同じく全周波数において吸収率が一貫して低下した. 一方, 図 C.7 の p-偏光では, θ_1 が増加したとしても, $\theta_1 = 30^\circ$ 程度までならば設計目標の 20 dB を W バンド全体で概ね達成した. 表 4.2 で示した他の論文では, 設計目標を 10 dB としたものが多かった. 我々の 3 層広帯域 MLA は, 両偏光において $\theta_1 = 0^\circ$ – 60° で 10 dB の目標を達成した. ADAS 市場向けの最新世代のレーダーセンサー「Bosch Gen 5 フロントレーダー」の水平視野角は 0° – 60° であることから [65], 設計した MLA は角度依存性が低く, 実用的であるといえる. 表 C.2 に広帯域吸収体の許容入射角度の比較を示す. 許容入射角度は両偏光ともに 10 dB 以上の吸収率を示す範囲を示してある. 我々の 3 層広帯域 MLA はこれらの文献において最も薄く, 入射角度の許容範囲も広い.




図 C.4 簡略化した狭帯域 MLA の s-偏光における入射角度依存性




図 C.5 簡略化した狭帯域 MLA の p-偏光における入射角度依存性




図 C.6 簡略化した広帯域 MLA の s-偏光における入射角度依存性




図 C.7 簡略化した広帯域 MLA の p-偏光における入射角度依存性

表 C.2 広帯域吸収体の許容入射角度の比較. 角度は両偏光ともに 10 dB 以上の吸収率を示す許容範囲である.

Thickness (mm)	Incidence angle	Reference
1	0 – 45°	[84]
1	0 – 56°	[85]
0.526	0 – 45°	[87]
0.7	0 – 40°	[72]
0.74	0 – 45°	[76]
0.5	0 – 60°	This work

付 録 D

研究業績

学術論文

1. Tomoya Momose, Mana Toma, and Kotaro Kajikawa. Ultrabroadband invisibility cloaking design of a concentric multilayered cylindrical metamaterial. *J. Opt. Soc. Am. B*, Vol. 41, No. 8, pp. 1815–1820, August 2024. Publisher: Optica Publishing Group.
2. Tomoya Momose, Hirofumi Kondo, Masamitsu Haemori, and Kotaro Kajikawa. Design of thin multilayer absorbers of graphite/polymer composites for W-band millimeter waves. *Japanese Journal of Applied Physics*, Vol. 64, No. 2, p. 022003, February 2025. Publisher: IOP Publishing.

国際会議における発表（査読あり，口頭発表）

1. Tomoya Momose, Mana Toma, Kotaro Kajikawa, “Broadband invisibility cloaking design of concentric multilayered cylindrical metamaterials based on genetic algorithm” , The 13th International Conference on Metamaterials, Photonic Crystals and Plasmonics (META 2023), Session 4A16, Paris, (2023.7.21).

国内学会における発表（全て査読なし，1–4: 口頭発表，5: ポスター発表）

1. 百瀬智也，當麻真奈，梶川浩太郎，“光学クローキング設計における機械学習と遺伝的アルゴリズムの比較”，第 82 回応用物理学会 秋季学術講演会，応用物理学会，12p-N202-2，オンライン，(2021.9.12).
2. 百瀬智也，當麻真奈，梶川浩太郎，“Design of optical cloaking by genetic algorithm

- and neural network” , JSAP 第 6 回フォトニクスワークショップ, 応用物理学会 フォトニクス分科会, 5-E-3, オンライン, (2021.11.5).
3. 百瀬智也, 當麻真奈, 梶川浩太郎, “遺伝的アルゴリズムとニューラルネットワークを用いた光学クロッキング設計” , 第 69 回応用物理学会 春季学術講演会, 応用物理学会, 24p-E303-13, オンライン, (2022.3.24).
 4. 百瀬智也, 當麻真奈, 梶川浩太郎, “遺伝的アルゴリズムを用いた多層円筒構造の広帯域な光学クロッキング設計” , 第 83 回応用物理学会 秋季学術講演会, 応用物理学会, 23p-A101-12, 東北大学, (2022.9.23).
 5. 百瀬智也, 當麻真奈, 梶川浩太郎, “メタマテリアルを用いた広帯域な光学クロッキング” , JSAP 第 7 回フォトニクスワークショップ, 応用物理学会 フォトニクス分科会, 1-P-44, 沖縄県青年会館, (2022.11.25).