

分光スペクトルを用いた調光機能のある 白色LEDの個体識別

藤 聡子^{1,a)} 土屋 彩夏¹ 李 陽¹ 崎山 一男¹ 菅原 健^{1,b)}

受付日 2020年12月2日, 採録日 2021年6月7日

概要: 照明やインジケータとして, LEDは広範囲に応用がされている. そこで, LEDを搭載した機器の真贋判定などの応用を目的として, LEDの個体識別が研究されてきた. 特に, 照明・インジケータにおいては, LEDを pulse-width modulation (PWM) により変調することで明るさを調節する(調光する)ことが一般的である. PWMを考慮したLEDの個体識別法は従来も存在したが, (i)計測時にPWMのデューティ比を掃引して繰り返し計測する必要があるとともに, (ii)識別器としての性能評価は行っていなかった. それに対し本論文では, 機械学習アルゴリズムを用いてLEDの個体に対応する多群識別を行う. 学習フェーズにおいて, 異なるデューティ比による分光スペクトルを用いることで, デューティ比による違いを識別器が吸収してくれる. その結果, 認証時にデューティ比を変化させる必要がなくなり, 個体識別の利便性が向上する. 性能評価実験を行った結果, 機械学習アルゴリズムとして K-Nearest Neighbor を使えば, 40クラスの多群識別において98.5%の成功率を達成することが分かった. 従来法の結果と比較した場合, (i)個体数が10から40に増加するとともに, (ii)デューティ比が異なるデータが混ざるという不利な条件にもかかわらず, ほぼ同等の性能であった.

キーワード: LED, 人工物メトリクス, 分光スペクトル, 機械学習

Spectral Fingerprinting of Dimming White LEDs

AKIKO TOH^{1,a)} AYAKA TSUCHIYA¹ YANG LI¹ KAZUO SAKIYAMA¹ TAKESHI SUGAWARA^{1,b)}

Received: December 2, 2020, Accepted: June 7, 2021

Abstract: Light-emitting diode (LED) is widely used for lighting and indicators. There is a recent line of works on fingerprinting LEDs, and they have a wide variety of applications, including supply-chain integrity and device authentication. White LEDs for lighting commonly have dimming capability using pulse-width modulation (PWM). There is a conventional preliminary work of fingerprinting dimmable white LEDs; however, (i) it does not evaluate the classification performance and (ii) the method is inefficient as we should repeat the measurements with different duty cycles. To tackle the problem, we study a method for fingerprinting dimmable white LEDs using a machine-learning classifier. In the proposed method, we train a multi-class classifier by feeding many spectra with different duty cycles. By using the classifier, we can ignore the duty cycle during the measurement, which significantly reduces the effort for measurement. With the spectral data from 40 LED samples from the same lot, the proposed method achieved the success rate of 98.5% in the 40-class classification experiment, which is comparable to the conventional results by Toh et al. using only 10 samples without dimming.

Keywords: LED, Artifact-metrics, Spectrum, Machine learning

1. はじめに

個体を見分けること(個体識別)は, セキュリティを支える基盤である. 最も応用が進んでいる個体識別はバイオメトリクスである. たとえば指紋認証では, 指紋のパター

¹ 電気通信大学情報理工学研究所
Department of Informatics, The University of Electro-Communications, Chofu, Tokyo 182-8585, Japan
a) akiko-to@nec.com
b) sugawara@uec.ac.jp

ンがある個人に固有であることを利用する。入力した指紋画像と、あらかじめ登録しておいたものを比較することでその個人を見分け、情報システムへのアクセス制御を行うことができる。また、より広い意味では、違いに乏しい対象物に対し、ネームプレートやステッカなどの識別子も貼り付けることもまた個体識別であるといえる。

1.1 工業製品の個体識別

工業製品の個体識別は、製品のトレーサビリティ確保や真贋判定などの広い応用がある。そこで、製造ばらつきを用いることで、大量生産された工業製品の個体識別を行うための技術が研究されている [1], [2], [3], [4], [5], [6]。多くの従来法は、対象物の写真をとり、画像上の特徴を用いて個体識別を行うというアプローチをとってきた。有名な研究として、Buchanan ら、および Clarkson らは、繊維のパターンにより紙を個体識別する方法を提案している [1], [2]。また、Takahashi らは、金属の表面のパターンを用いてネジなどの金属製品を個体識別する方法を提案している [3]。より最近では、Dhanuskodi らが、プラスチックパッケージ表面のパターンを観察することで、IC 部品を個体識別する方法を提案した [4]。以上とは独立に、無線機の個体識別 (RF fingerprinting) も研究がされてきた [7]。これは、無線機から放出された電波の特徴を見ることで、無線機を個体識別することを目的とするものである。無線機の個体識別は、遠隔から非接触で行うことができるため、通信相手の認証に利用できる。通信相手が意図した無線機であることを確認することで、リレー攻撃などのアナログ領域での攻撃を防ぐことに応用できる。

1.2 LED を個体識別

LED (発光ダイオード) は、照明や、電子機器のインジケータとして近年身近に普及している。LED の個体識別が可能であれば、LED を応用するそれらの製品のトレーサビリティ確保や真贋判定に広い応用が期待できる。また、LED は、近年普及が期待される可視光通信の光源としても用いられる [8]。LED の個体識別ができれば、無線機の個体識別と同様に通信相手の認証に利用することで、可視光通信におけるリレー攻撃対策に応用できる可能性もある。

以上の背景より、LED の個体識別が研究されてきた [9]。LED は、点光源のため空間的なパターンを持たず、また個体ごとの色の選別 (LED binning) により色の違いがイメージセンサでは検出できないため、従来の画像処理による個体識別法 [1], [2], [3], [4], [5] を適用できない。それに対し藤らは、LED の分光スペクトルを用いて個体識別を行う方法を提案した [9], [10], [11]。LED に流す電流が一定である条件下では、異なる品番を見分けることも、同じ品番の異なる個体を見分けることも可能であることが示されている。また、特に後者では、機械学習を用いた識別におい

ても高い確率で識別が可能であることも示されている。

1.3 従来法の課題

普及する LED 照明に従来法 [9] を適用するときの大きなギャップは、ドライブ方式の違いにある。LED 照明は、光量を調節する機能 (調光機能) を持つことが一般的である。調光を行う一般的な方式はパルス幅変調 (PWM: Pulse-Width Modulation) である。すなわち、LED を人間が知覚できない速度で点滅させ、その際の ON/OFF の時間の割合 (デューティ比) によって光量を調節するのである。

調光は明るさを変える技術であるが、PWM 変調により分光スペクトルが変化することは周知であり [12], [13]、識別法に影響がある。従来法 [9] では調光は想定に入れられていなかった。また、従来法 [10] では、調光を考慮した拡張が行われたが、識別のためにスペクトルの変化と電力をすべて取得しなければならないこと、計測器のコストがかかるなどの問題が残った。また、前述したように普及する LED の調光方法である PWM とは異なる方法を用いていた。続く従来法 [11] では、PWM 環境下で行われているが識別のたびに複数のデューティ比を用いることを前提としており、またデータ加工を行っていることから識別は非効率であった。

1.4 貢献

今回は、上記課題を解決するため、PWM 環境下で取得した複数のデューティ比の分光スペクトルを学習させることにより、識別が可能か検証する。以下に、本論文の貢献とその要約、および対応する章を示す。

(1) 調光に対してロバストな個体識別の提案 (4 章): 対象 LED の調光が変化しても、それを気にすることなく個体識別をするための方法を初めて提案する。認証側が、被認証側のデューティ比を知ったり制御したりする必要がなくなるため、識別の利便性が向上する。

(2) 識別方式の提案 (4 章): 提案法は、従来法 [9] と同様に、機械学習アルゴリズムを用いて LED の個体識別を行う。調光状態によって分光スペクトルが変化するため、従来法を単純に使うことはできない。そこで、調光状態が異なるデータを混ぜて学習をすることで、調光に対してロバストな識別器を作る方法を提案する。より具体的には、ある有限のステップで明るさを調節できる LED を想定し、各ステップでの分光スペクトルを訓練データとして収集する。それらのデータを用いて学習することで、PWM のデューティ比による違いを吸収する識別器を作る。

(3) 個体識別の性能評価実験 (5 章): 同一番番・同一ロットの砲弾型白色 LED 40 個体を計測し、提案法の性能評価を行う。各個体について、11 段階の調光ステップ、5 回ずつ繰り返し計測し、2,200 サンプルのデータを得る。それ

らのデータをもとに、調光状態によって分光スペクトルが変化することを確認する。また、上記のデータを対象に40クラスの多群識別を行い、機械学習アルゴリズムとしてK-Nearest Neighborを使えば、98.5%の成功率を達成することを示す。これは、個体数が少なく、かつデューティ比の変化を考慮しない従来法 [9] と比較した場合とほぼ同等の性能である。

1.5 本論文の構成

本論文は次のように構成する。2章では準備として、工業製品の個体識別と白色LEDについて概説する。3章は、本研究の直接の元となるLEDの個体識別の従来法について述べる。4章で従来法の課題と提案法について述べる。5章では、提案法の性能評価実験について述べる。6章は結論である。

2. 準備

2.1 工業製品の個体識別

個体を見分けること（個体識別）は、セキュリティを支える基盤であり、個人（ユーザ）を見分けるためのバイオメトリクスが広く行われている。同様に、大量生産された工業製品の個体識別を行うための技術が研究されている。そのような技術には、サプライチェーン保全、フォレンジック調査、およびデバイス認証などの多くのセキュリティ応用がある [14]。そこで、大量生産された工業製品の個体識別を行う研究が存在する [1], [2], [3], [4]。

1つの研究の流れは、対象物の表面における画像上のパターン・特徴を用いる方法である。これまで、紙 [1], [2], ネジなどの金属部品 [3], およびICパッケージ [4] などの個体識別法が提案されてきた。また別の研究の流れは、無線機を個体識別するRF fingerprintingである [7]。これは、無線機そのものではなく、放出された電波の特徴を見て個体識別を行う点が上記の方法とは異なる。特に、遠隔から非接触で個体識別を行うことができる利点を活かし、通信相手の認証に利用することができる。

2.2 分光スペクトル

電磁波の一種である光は、その波長によって紫外線・可視光線・赤外線に分類される。これを、波長（または周波数）ごとの強度で表したものを分光スペクトルと呼ぶ。人間の目が感度を持つ可視光域は380nmから780nmに対応しており、短波長が紫、長波長が赤となる。所与の光を波長ごとに分解することを分光と呼ぶ。また、そのための装置を分光器と呼ぶ。多くの分光器は、プリズムにおける屈折や、回折格子における回折の度合いが、波長によって異なることを利用する。特に最近では、MEMS (Micro Electro Mechanical Systems) によって作った回折格子と、1次元イメージセンサを組み合わせることで、安く性能の

表 1 分光器から取得されるデータの形式

Table 1 Data format from the spectrometer.

波長	$\lambda(0)$	$\lambda(1)$	$\lambda(254)$	$\lambda(255)$
光量	$s(0)$	$s(1)$	$s(254)$	$s(255)$

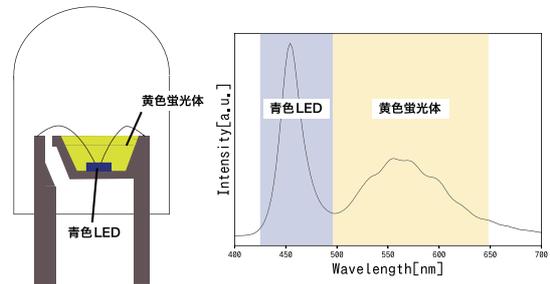


図 1 白色LEDの構造と分光スペクトル

Fig. 1 White LED and its spectrum.

高い分光器を入手することが可能になっている [15]。

分光器は、通常、波長を離散化し、それぞれの波長に対する強度を出力する。具体例として、本研究で用いる分光器（浜松ホトニクス C12666MA [15]）を例に説明する。表 1 に、分光器から取得されるデータの形式を示す。この分光器は、約 310 から 800 nm の可視光域を、256 段階に分割して計測する。その波長を、便宜上、 $\lambda(0)$ – $\lambda(255)$ と書く。計測を行うと、それら各波長に対応する光量 $s(0)$ – $s(255)$ を取得することができる。

2.3 白色LEDとそのスペクトル [16]

照明用に普及している白色LEDと、その分光スペクトルを図 1 に示す。そのような白色LEDは、青色LEDに黄色蛍光体を被せた構造を持つ（図 1）。黄色蛍光体は、フォトルミネセンスにより、LEDの青色光を吸収して黄色光を発する。補色関係に青色光と黄色光が混ざったものを、人は白色と認識する（擬似白色）。図 1 右は、そのような白色LEDの典型的な分光スペクトルである。450 nm 周辺にある鋭いピークが青色LEDによる光であり、500 nm から 600 nm にかけて存在するなだらかな山が黄色蛍光体による光である。

2.4 パルス幅変調による調光

LED照明は、光量を調節する機能（調光機能）を持つことが一般的である。調光には、2つの代表的な方式がある [17]。1つはLEDを駆動する電流量を制御する波高値制御方式である。2つ目はPWM制御方式である。PWM方式では、図 2 に示すように、電圧は一定に保ちながら、点灯時間（ON）と消灯時間（OFF）の比によって調光を行う。1周期におけるONである時間の割合をデューティ比と呼ぶ。そのほかに、周期の長さやON時の電圧が、PWMを定めるパラメータである。PWM制御方式はデジタル制御が容易であるため、LED照明で広く利用されている。

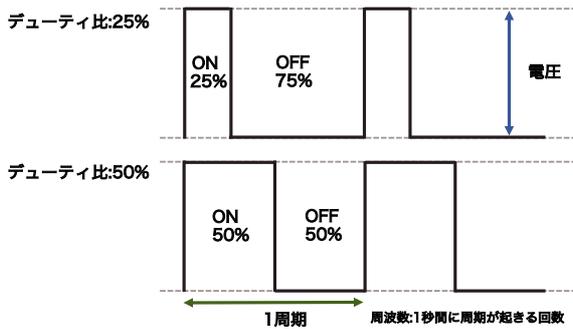


図 2 Pulse Width Moduration (PWM) による調光
Fig. 2 Dimming based on Pulse width modulation.

3. 白色 LED の個体識別

近年は LED の普及が著しく、照明だけでなく、ディスプレイ、信号機、プロジェクタ、バッテリーなどのインジケータなどの広範で利用されている。LED の個体識別ができれば、それら製品のトレーサビリティ確保や真贋判定などの広い応用が存在する。加えて、LED は、近年普及が期待される可視光通信の光源としても用いられる [8]。また、光源としての LED を識別できるならば、可視光通信におけるリレー攻撃への対策に活用できると考えられる [7], [18]。

以上の背景のもとで、白色 LED の個体識別が研究されてきた。LED を個体識別をするうえでの課題は、空間的なパターンを持たない (1 画素分の情報しかない) ことにある。そのため、従来法のようにカメラで撮った画像を用いることができない。それに対し、分光スペクトルを用いて白色 LED の個体識別を行う一連の研究がある [9], [10], [11]。本章では、それら従来法の特徴と、本研究の動機となる課題について述べる。本研究においては、機器の製造者のオペレータが、工場もしくはフィールドにおいてトレーサビリティの検証のために計測するような用途を想定している。また、識別を行う人は LED の分光スペクトルを計測することだけを可能な能力とし、このときデューティ比の調整を不要と仮定している。

3.1 定電流計測と機械学習 [9]

従来法 [9] は最も初期の方法であり、最もシンプルな条件として、ある同一の電圧で駆動する条件において個体識別を行っている。まず、異なる製造者・異なる品番による LED は、黄色蛍光体による分光スペクトルの差を用いて、容易に識別可能であることを示している。また、同一品番の LED 間も、青色 LED による分光スペクトルの差を用いて識別可能であった。

従来法 [9] は、機械学習アルゴリズムによる識別器の性能評価も行っている。表 2 は、適切に前処理したデータを教師あり機械学習アルゴリズムに入力し、交差検証により性能評価を行った結果である。これは、10 個体を見分ける

表 2 文献 [9] による定電流環境下の 1 つの明るさを用いた場合の 10 個体の識別結果

Table 2 Classification result with 10 samples under a constant current in the previous study [9].

識別器	成功率
K-Nearest Neighbor	0.98
Perceptron	0.49
Logistic 回帰	0.99
GaussianNB	0.96
Decision Tree (分類)	0.76
Random Forest (分類)	0.88
Multilayer Perceptrin	0.94
Support Vevctor Machine (分類)	0.22
Adaptivve Boosting	0.31

多群識別問題であり、適切なアルゴリズムを選択すると、95%を超える高い成功率を示すことが分かった。

3.2 駆動電圧計測による識別 [10]

従来研究 [10] は、耐クローン性の向上を目的として、LED を駆動する電流・電圧量を変化させる個体識別法を提案した。この方式の動機として、正規化を悪用したクローン作成がある。また、以上の手法では、計測環境に敏感な光量の影響を緩和するため、従来法 [9] では総光量の総和を一定にする正規化を、従来法 [10] の基礎実験では、光量の最大値と最小値の差を一定にする正規化する方法を用いていた。これらの方法は、一方で、クローンを作ろうとする攻撃者に操作できる自由度を与えることになる。実際、実験により意図的に別個体で同一の分光スペクトルを持つケースが存在した。

従来法 [10] は、以上の課題を解決するために、スペクトルそのものではなく、電力に対する青色 LED のピーク波長の遷移を利用する方法を提案した。後の 5.3 節の実験で述べるとおり、LED を駆動する電力を変化させると、青色 LED のピーク波長がシフトする。そのとき、駆動する電力とピーク波長の軌跡が、LED の個体を見分ける特徴として利用できる。その結果、個体識別が可能という結果を得た。このとき光量は治具で装置を固定することにより、計測を安定させる必要があった。

3.3 PWM 計測での駆動電圧計測置き換え [11]

従来研究 [11] は、従来研究 [10] において必要であった可変電圧源を PWM に置き換える方法を提案した。そうすることによって、個体識別のために専用に必要であった可変電圧源を廃することができる。その代わりに PWM が必要となるが、これは調光機能のために元々備わっているものを用いることができる。以上により、識別に必要な装置を低コスト化することができる。

可変電圧源により LED の明るさを変えることは、2.4 節

で説明した波高値制御方式による調光に等しい。これを、より安価で一般的な調光方式である PWM に置き換えるという点がアイデアである。実際、PWM による調光でもピークシフトが起きることが知られている [12], [13]。

4. 提案法

4.1 従来法の課題

表 3 に基づき、従来法の課題と、提案法の関係について論じる。

従来法 [9] は、LED の個体識別の実現可能性を実証したが、いくつかの課題も残った。特に、正規化により光量の情報が失われることは、クローンを作ろうとする攻撃者に操作できる自由度を与えることになった。続く従来研究 [10] は、先の研究の欠点を補うために（光量に相関を持つ）電圧とピーク波長の関係の特徴量として用いることで、特徴量に光量の情報を取り込んでクローン耐性の向上を達成した。しかし、識別の際は、LED をドライブする電圧を変化させながら複数回の計測が必要となった。その結果、LED の側に可変電圧源が必要となり、コストが上がるという欠点となった。さらに次の方式 [11] は、可変電圧源を PWM で置き換えられることを示した。そうすることで、可変電圧源が高コストであるという課題を解決した。しかし、この方法を、先の研究 [10] の識別法と組み合わせた場合であっても、識別時に、LED 側が PWM のデューティ比を掃引しなくてはならないという不便は残った。また、従来法では実験に用いた個体数は少なく、従来研究 [9], [10], [11] ではそれぞれ 10, 5, 15 個体に限られていた。

機械学習に着目すると、これまで導入したことがある研究は従来法 1 [9] のみである。また、このときに用いたデータは 1 つの明るさのみであらかじめ視覚的に識別できていたものである。数値から識別可能と判断できるか、検証のための識別法としては行っていない。

4.2 提案法

提案法は、従来法 [9] と同様に、機械学習アルゴリズムを用いて LED の個体に対応する多群識別を行う。ただし、学習フェーズにおいて、ありうるデューティ比すべての分光スペクトルを教師データとして与える。そうすることで、PWM のデューティ比による違いを考慮した識別器を作る。識別フェーズでは、対象の LED から計測した分光

スペクトルを、デューティ比を気にすることなく識別器へ入力する。識別器が、デューティ比の違いを吸収するので、認証側は被認証側のデューティ比を気にしなくてもよくなる。そうすることにより、識別時に、LED 側でデューティ比を掃引する必要がなくなる。以上から提案法は、デューティ比が違っていても識別が可能であり、装置へ非接触での識別ができるため、利便性が向上すると考えられる。

なお、提案法は、特に LED の個体識別を目的とする。真贋判定など、能動的な攻撃が想定される用途で用いるには、さらに、クローン攻撃への耐性（耐クローン性）が求められる。提案法に対する耐クローン性の安全性評価は、本論文の範囲外であり、今後の研究課題である。

5. 実験

提案法の有効性を検証するために、LED 40 個体を、異なる調光（PWM におけるデューティ比）で計測する。また、計測の再現性の評価のために、各条件につき 5 回繰り返し計測を行う。5.1 節では、セットアップと計測手順を述べる。5.2 節では、事前準備として、計測データの再現性の評価を行う。5.3 節では、PWM 環境でユーザが動かせるパラメータであるデューティ比のスペクトルに対する影響を検証する。5.4, 5.5 節では実際に LED の個体差について実験とその結果から考察を行い、最後の 5.6 節では、機械学習による識別実験を行う。

5.1 セットアップ・手順

図 3 にセットアップを示す。また、図 4 は図 3 をブロック図で表したものである。電流コントローラで対象の LED を駆動し、その光を積分球で集め分光器（浜松ホトニクス C12666MA）で計測して分光スペクトルを得る。従来法 1 では、光量の是正のために正規化を行っていた。これは、繰り返しの計測で装置への LED の取り付け時にずれが生じて取得光量がぶれていたためである。本実験では取り付けの際のずれがあったとしても取得光量に影響がないように、積分球を用いる。LED と分光器は光学定盤に

表 3 従来法と提案法の比較

Table 3 Comparison of previous and proposed methods.

	光量情報を使うか	機械学習	調光状態の制御が必要か
提案法	✓	✓	✓
従来法 1 [9]	×	✓	—
従来法 2 [10]	△	×	×
従来法 3 [11]	△	×	×

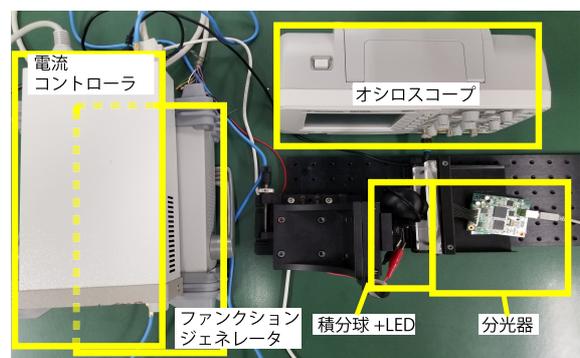


図 3 実験環境

Fig. 3 Experimental setup.

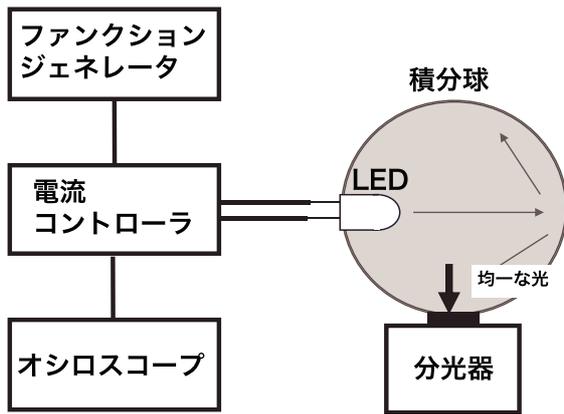


図 4 実験環境のブロック図

Fig. 4 Block diagram of the Experimental setup.

固定した. PWM 変調は, ファンクション・ジェネレータ (Rigol DG1022) で生成したパルス波を, 電流コントローラ (Thorlabs LDC202C) の変調ポートに入力することで行う. 変調の様子は, 電流コントローラのモニタ出力をオシロスコープで観察して確認する. ファンクション・ジェネレータが出力する PWM 波形は, 電圧を 4.5 V, 周波数を 1 kHz とした. また, デューティ比は, 後述のとおり, 実験によって変えた*1.

発光直後時の LED の温度変化を考慮して, 計測は発光開始から 10 秒後に行った. 分光器の蓄積時間はすべて 1 ms とした. また, 分光スペクトルは, いずれも 100 回ずつ計測して平均をとることでノイズ除去を行った. 1 回の計測時間は 11 秒程度である (10 秒 + 1 ミリ秒 × 100 回). 今回用いた LED は, CREE 社の C513A-WSS-CW0Z0152 を 40 個体用いて実験を行った. 基礎実験では 1 個体, 個体差を確認する実験では 40 個体すべてを使用した.

なお, デューティ比は, 次の 11 段階とした:

$$\{1\%, 10\%, 20\%, 30\%, 40\%, 50\%, 60\%, 70\%, 80\%, 90\%, 99\%\}. \quad (1)$$

これは, ステップ幅を 10% 刻みとして得たものである (0, 100% は, それぞれ 1% と 99% で代用している). 実際, 照明機器においては, その程度の段階で調光する製品 (10 段階調光) が販売されているため, 現実的な設定であるといえる [19]. また, 見た目への要求が低いインジケータ用途では, 調光ステップはさらに少なくなると考えられる.

取得したデータおよびパラメータは以下の式で定義する.

$$S_{i,j,k} \in \mathbb{R}^{256} \quad (2)$$

ただし, $i \in [0, 39]$ は個体を表す添字,

$$j \in \{1\%, 10\%, 20\%, 30\%, 40\%, 50\%, 60\%, 70\%, 80\%, 90\%, 99\%\} \quad (3)$$

*1 電流コントローラの都合上, 0.08 mA のオフセットが追加された状態で計測した.

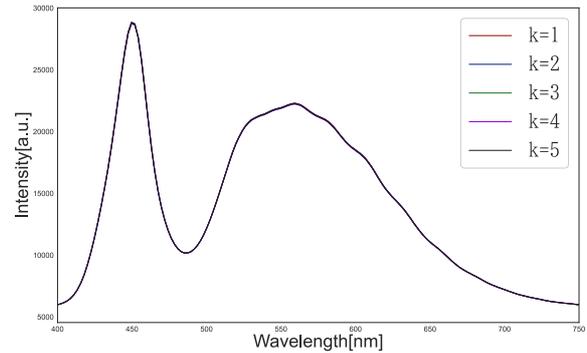


図 5 繰り返し計測による再現性の評価: 同一個体・同一デューティ比複数回計測して得た分光スペクトル

Fig. 5 Evaluation of reproducibility in measurements: spectra from the same sample and duty cycle with repeated measurements.

はデューティ比, $k \in [0, X - 1]$ は計測の試行を表す添字である.

5.2 実験 1: 繰り返し誤差の評価

まず, セットアップにおいて, LED の取り外し・取り付けに起因する繰り返し誤差を評価する. そのために, 個体とデューティ比を固定して複数回計測した. そのうち (4.5 V, 50%, 1 kHz) のパラメータのものを代表して記載する. ただし, 計測のたびに, LED の取り外し・取り付けを行った. この実験は, 式 (2) のパラメータのうち, i, j を固定し k のみを変動させたものに該当する. ある特定の個体に対して, 5 回計測して得たスペクトルを重ねてプロットしたものを図 5 に示す. 縦軸が光量, 横軸が波長を示す. グラフより, 5 回の計測で得たスペクトルがほぼ一致することが分かる. この結果より, 本実験はスペクトルの計測において高い再現性があるといえる. なお, 図は省略するが, 実験対象の 40 個体すべてで同様の評価を行い, 高い再現性があることを確認した.

5.3 実験 2: デューティ比の変化に対するスペクトル形状の変化

PWM のデューティ比を変化させることによって生じる分光スペクトルの変化を評価する. そのために, ある特定の個体において, デューティ比のみを変化させた際の分光スペクトルを比べた. この実験は式 (2) のパラメータ, i, k を固定し j のみを変動させる実験にあたる.

異なるデューティ比による分光スペクトルを図 6 に示す. 縦軸は光量, 横軸が波長である. まず, デューティ比に応じてスペクトルが全体的に上方方向へと変化しており, これは, デューティ比によって光量が増加することに対応している. 光量だけでなく, デューティ比によって波長にも変化が生じる. デューティ比が増加するにつれて, 一番光量の多い波長が長波長側へとシフトしていることが確認

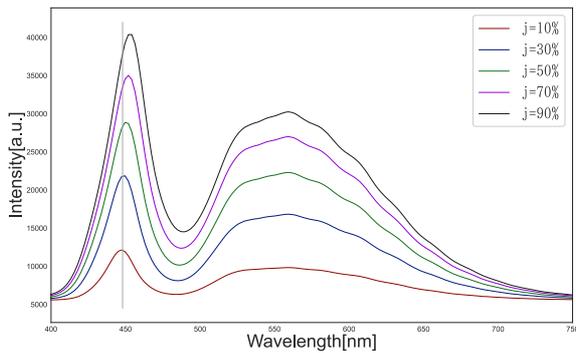


図 6 同一個体・複数のデューティ比の分光スペクトル

Fig. 6 Spectra of the same sample under the different duty cycles.

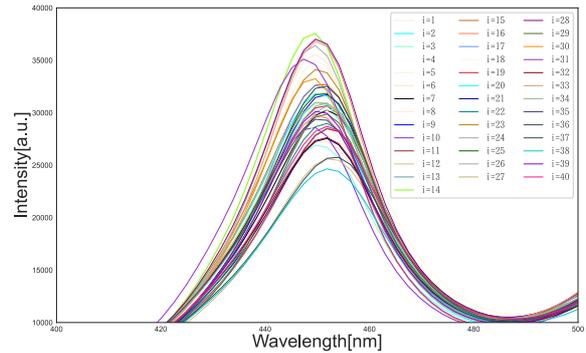


図 8 デューティ比 50% 固定時の 40 個体の比較

(図 6 の 450 nm 付近を拡大したもの)

Fig. 8 Spectra from 40 samples under the 50% of duty cycle (magnification of Fig. 6 around 450 nm).

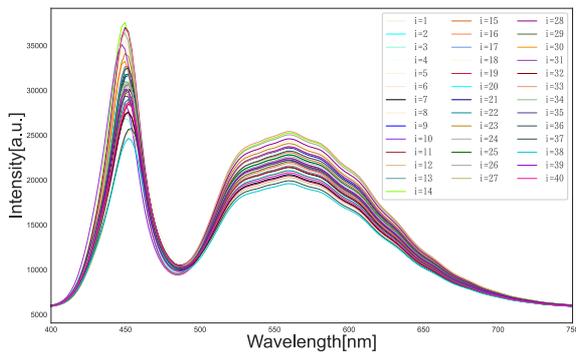


図 7 デューティ比 50% 固定時の 40 個体の比較

Fig. 7 Spectra from 40 samples under the 50% of duty cycle.

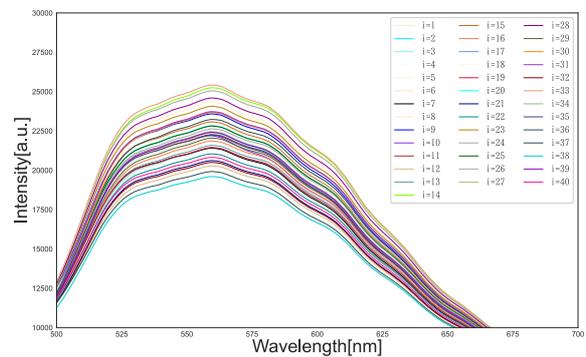


図 9 デューティ比 50% 固定時の 40 個体の比較

(図 6 の 570 nm 付近を拡大したもの)

Fig. 9 Spectra from 40 samples under the 50% of duty cycle (magnification of Fig. 6 around 570 nm).

できる (参照のため、デューティ比 10%におけるピーク波長に補助線を引いた)。よって、デューティ比を変化させることは、図 6 のようなグラフを縦にスケールする以上の変化を生じることが分かる。

5.4 実験 3: LED の個体差

まず、デューティ比を固定した場合の LED の個体差を評価する。そのために、デューティ比を 50%に固定して個体のみを変えたデータを図 7 に示す。縦軸が光量、横軸が波長を示す。これは、式 (2) のパラメータのうち、 j , k を固定し i を変動させた実験であり、40 個体に対応する 40 本のグラフを重ねて表示している。

従来研究と同様に、分光スペクトル上で個体差が観察できる。特に差が大きい青色 LED と黄色蛍光体の領域を拡大したものを図 8 と図 9 にそれぞれ示す。図 8 は、青色 LED 発光部分である波長 450 nm 周辺を拡大してプロットしたものである。個体によって、光量も一番強い光量の波長も異なることが確認できる。図 9 は、黄色蛍光体発光部分である約 500 nm から 600 nm 付近をプロットしたものである。こちらでは、おおよそのスペクトルは同じ形だが光量の大きさが個体ごとに異なることが確認できる。以上の 3 つから、同じ入力パラメータに対して大きく 2 つの波長域で個体差が存在することを確認できる。

5.5 実験 4: 複数のデューティ比と複数の個体

ここまではデューティ比 50%を対象とした結果である。本節では、異なるデューティ比における結果について論じる。各デューティ比における、全個体の分光スペクトルを重ねてプロットしたものを、図 10 に示す。

ここまで見てきたように、デューティ比を増やすにつれ、スペクトルの強度が増加する。また、デューティ比が増加するにつれ、個体ごとの差が顕著になるということが特筆すべき傾向である。ただし、分光スペクトルの軌跡が個体ごとに区別可能であるのは、どのデューティ比であっても同様である。特に、図 10 において、デューティ比 1%のスペクトルは潰れて見えるが、拡大すれば、図 8, 9 と同様の波形を見ることができる。

各デューティ比における (個体差による) スペクトルの幅を比較する。図 10 (1) は、各デューティ比において観測したスペクトルの範囲を図示したものである。前述のとおり、デューティ比を増やすにつれスペクトルの強度は増加するものの、増え方は各個体で一定ではなく、領域間には重なりがあることが分かる。よって、40 個体で複数の明るさを合わせた状態では、単純なしきい値などでは識別ができないことが分かる。

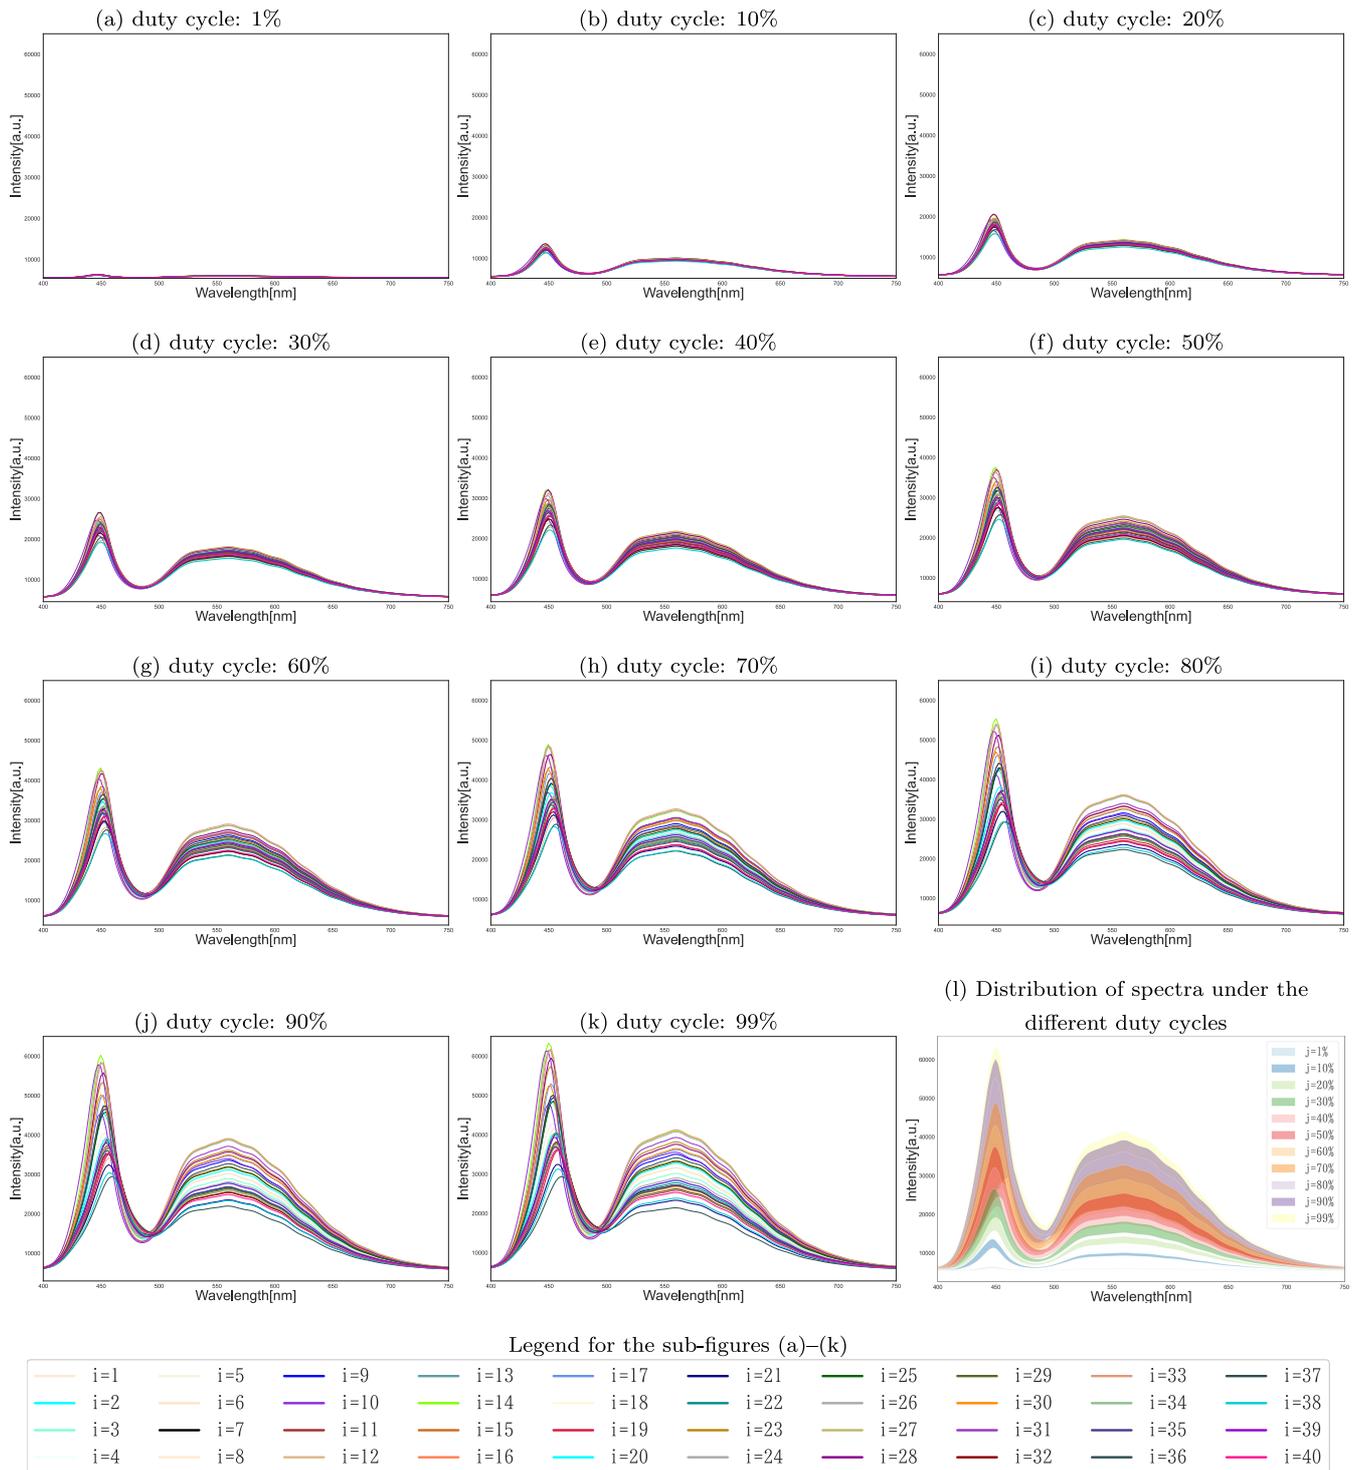


図 10 (a)–(k) : 各デューティ比における, 全個体の分光スペクトル. (l) : 各デューティ比において観測したスペクトルの幅を重ねて図示したもの

Fig. 10 (a)–(k): Spectra from 40 samples under each duty cycle. (l): Distribution of spectra under the different duty cycles.

5.6 実験 5 : 機械学習を用いた識別

この章では, ここまで見た計測データを, 教師あり学習アルゴリズムにより識別して性能評価を行う.

学習アルゴリズムにおける説明変数は分光スペクトルで計測した 256 次元のベクトルである. なお, 従来法 [9] とは異なり, 正規化などは行わず, 分光器の出力をそのまま用

いた. また, 目的変数は, 個体を表すインデックス i である. 40 個体あるため, これは 40 クラスの多群識別問題である. 取得したデータは LED 40 個体を, 11 段階のデューティ比で計測したものであり, 各条件で 5 回繰り返し計測を行った. そのため, 計測データは 2,200 サンプルある (40 個体 \times デューティ比 11 段階 \times 計測繰り返し数 5 回).

表 5 機械学習アルゴリズムのグリッドサーチにおける対象パラメータ一覧

Table 5 The target parameters for the grid-search parameter tuning in the machine learning algorithm.

識別器	パラメータ
K-Nearest Neighbor	n_neighbors=[1, 3, 5, 7, 9, 11, 13, 15, 17, 19, 21, 23, 35, 27, 29], weights=["uniform", "distance"], leaf_size=[10, 20, 30, 40, 50, 60, 70, 80, 90], p=[1, 2]
Perceptron	alpha=[1e-5, 1e-4, 1e-3, 1e-2, 1e-1, 1, 1e+1, 1e+2, 1e+3, 1e+4, 1e+5], max_iter=[1000, 2000, 3000], tol=[1e-6, 1e-5, 1e-4, 1e-3, 1e-2, 1e-1]
Logistic 回帰	C=[1e-5, 1e-4, 1e-3, 1e-2, 1e-1, 1, 1e+1, 1e+2, 1e+3, 1e+4, 1e+5], solver=["liblinear", "newton-cg", "lbfgs", "sag", "saga"], multi_class=["auto", "ovr", "multinomial"], max_iter=[100, 500, 1000]
GaussianNB	var_smoothing=[1e-10, 1e-9, 1e-8, 1e-7, 1e-6, 1e-5, 1e-4, 1e-3, 1e-2, 1e-1, 1, 1e+1, 1e+2, 1e+3, 1e+4, 1e+5]
Decision tree (分類)	criterion=["gini", "entropy"], max_depth=[1, 50, 100, 150, 200, None], min_samples_split=[1, 2, 3, 4, 5, 6, 7, 8, 9], min_samples_leaf=[1, 2, 3, 4, 5, 6, 7, 8, 9]
Random Forest (分類)	n_estimators=[10, 20, 30, 40, 50, 60, 70, 80, 90, 100], criterion=["gini", "entropy"], max_depth=[1, 50, 100, 200, None], bootstrap=[True, False], min_samples_split=[2, 5, 10], min_samples_leaf=[1, 5, 10]
Multilayer perceptron	hidden_layer_sizes=[10, 100, 1000], solver=["sgd", "adam", "lbfgs"], activation=["identity", "logistic", "tanh", "relu"], learning_rate=["constant", "invscaling", "adaptive"], learning_rate_init=[0.1, 0.01, 0.001]
Support Vector Machine (分類)	C=[1e-5, 1e-4, 1e-3, 1e-2, 1e-1, 1, 1e+1, 1e+2, 1e+3, 1e+4, 1e+5], kernel=["linear", "poly", "rbf", "sigmoid"], gamma=["scale", "auto"]
Adaptive Boosting	base_estimator=DecisionTreeClassifier(max_depth=n)[n=5, 6, 7, 8, 9], learning_rate=[0.5, 1.0, 1.5], n_estimators=[50, 60, 70, 80, 90, 100], algorithm=["SAMME", "SAMME.R"]

表 4 各機械学習アルゴリズムによる 40 群識別の成功率

Table 4 Success rate of 40-class classification using different machine-learning algorithms.

識別器	成功率
K-Nearest Neighbor	0.987
Perceptron	0.090
Logistic 回帰	0.960
GaussianNB	0.068
Decision tree (分類)	0.831
Random Forest (分類)	0.971
Multilayer perceptron	0.089
Support Vector Machine (分類)	0.939
Adaptive Boosting	0.969

評価方法：k 分割交差検証 (K-fold Cross-validation) により性能評価を行った。k 分割交差検証は、全体のデータを k 個に分割しそのうちの 1 つをテストデータに、その他のデータを訓練データとする。テストに用いるデータを入れ替えながら k 回機械学習を行うことで、特定のテストデータの結果に偏ることを防ぐ。本実験では k=5 で行っている。機械学習アルゴリズムとその実装は、従来法 [9] と同じであり、機械学習ライブラリ scikit-learn の 9 つの代表的な教師あり学習アルゴリズムを評価対象とした。このデータを k 分割交差検証法を用いて機械学習にかけた。

パラメータチューニング：機械学習アルゴリズムのハイ

パーパラメータは、各パラメータで用いる候補の値の組合せを全通り試していく手法であるグリッドサーチを用いてチューニングした。scikit-learn におけるグリッドサーチの実装である GridSearchCV() を用い、表 5 に記載するパラメータを探索した。以上の結果、最良と判断されたパラメータ*2 を採用した。各機械学習アルゴリズムで最終的に利用したパラメータは表 A.1 に示すとおりである。

性能評価：表 4 に識別実験の結果を示す。成功率は機械学習アルゴリズムによって大きく異なる。K-Nearst Neighbor の性能が良く、成功率 98.5% を達成できることが分かった。従来法 [9] の結果 (表 2) と比較した場合、(i) 個体数が 10 から 40 に増加するとともに、(ii) デューティ比が異なるデータが混ざっているにもかかわらず、性能の劣化はほぼない。この傾向は、K-Nearst Neighbor に特有のもので、従来法では高い性能を発揮した Logistic 回帰や GaussianNB は、本研究では大きく性能を落としている。

考察：結果より、多くの機械学習アルゴリズムにおいて、高い成功率を得た。すなわち、デューティ比を変えたものを混ぜた場合であっても、高い精度で識別が可能であることが分かる。機械学習アルゴリズムの違いに対するロバストさは、対象のデータそのものの分離性が良いことに由来すると考えられる。これは、図 10 において、グラフが目

*2 関数の属性 best_params_ で得られるもの。

で見て分かるほど分離をしているという結果と整合している。Perceptron・Multilayer Perceptron がともに性能が悪いことから、データが、Perceptron にとって苦手な特徴を持っている可能性が示唆される。しかし、具体的な理由付け・解釈は今後の課題である。GaussianNB 分類器の結果が悪くなった理由としては、PWM を変えたことでデータの自由度が上がったことが考えられる。

6. 結論

PWM による調光がある場合の LED の個体識別法を提案した。提案法は、従来法 [9] と同様に、機械学習アルゴリズムを用いて LED の個体に対応する多群識別を行う。ただし、PWM による光量の変化を考慮するために、ありうるデューティ比すべての分光スペクトルを学習フェーズにおいて教師データとして与える点が大きく異なっている。

性能評価実験を行った結果、機械学習アルゴリズムとして K-Nearest Neighbor をはじめとする複数の分類器を使えば、40 クラスの多群識別において、高い成功率を達成することが分かった。従来法 [9] の結果 (表 2) と比較した場合、(i) 個体数が 10 から 40 に増加するとともに、(ii) デューティ比が異なるデータが混ざるという不利な条件にもかかわらず、性能の劣化はほほない。

提案法では、識別器が、デューティ比の違いを吸収するので、認証時にデューティ比を気にしなくてもよくなる。すなわち、認証のために LED 側がデューティ比を掃引して繰り返し計測する必要がなくなる。その結果、方式の簡便性が向上するとともに、識別に要する時間も短縮できると考えられる。

機械学習アルゴリズムのチューニングと、性能差の分析・考察には改善の余地がある。また、今後の課題としては識別に有効な特徴の特定と識別可能な個体数の調査を行いたいと考えている。特に、さらに個体数が増加したり、デューティ比の刻みが増加したりした際には性能の低下が見込まれる。そのため、LED の識別子を利用した 1 対 N 認証への拡張が次なる研究課題であると考えている。他の研究課題として 4.2 節に記載したように、能動的な攻撃が想定したとき、耐クローン性の安全性評価を行う必要がある。

謝辞 本研究は JSPS 科研費 JP18H05289 の助成を受けたものです。

参考文献

[1] Buchanan, J.D.R., Cowburn, R., Jausovec, A.V., Petit, D., Seem, P., Xiong, G., Atkinson, D., Fenton, K., Allwood, D.A. and Bryan, M.T.: Forgery: ‘Fingerprinting’ Documents and Packaging, *Nature*, Vol.436, pp.475–475 (2005).

[2] Clarkson, W., Weyrich, T., Finkelstein, A., Heninger, N., Halderman, J.A. and Felten, E.W.: Fingerprinting Blank Paper Using Commodity Scanners, *IEEE Symposium on Security and Privacy* (2009).

[3] Takahashi, T. and Ishiyama, R.: FIBAR: Fingerprint Imaging by Binary Angular Reflection for Individual Identification of Metal Parts, *2014 5th International Conference on Emerging Security Technologies* (2014).

[4] Dhanuskodi, S.N., Li, X. and Holcomb, D.E.: COUNTERFOIL: Verifying Provenance of Integrated Circuits using Intrinsic Package Fingerprints and Inexpensive Cameras, *USENIX Security Symposium 2020*, pp.1255–1272 (2020).

[5] 矢ヶ崎玲奈, 崎山一男: ワイン瓶の透過光を用いた人工物メトリクスに関する研究, 電子情報通信学会 2015 年総合大会 (2015).

[6] 松本弘之, 宇根正志, 松本 勉, 岩下直行, 菅原嗣高: 人工物メトリクスの評価における現状と課題, 日本銀行研究所金融研究 (2004).

[7] Danev, B.D.: Physical-Layer Identification of Wireless Devices, Ph.D. Thesis (2011).

[8] 春山真一郎: 可視光通信, 電子情報通信学会誌, Vol.94, No.12, pp.1055–1059 (2011).

[9] Toh, A., Li, Y., Sakiyama, K. and Sugawara, T.: Fingerprinting Light Emitting Diodes Using Spectrometer, *IET Electronics Letters*, Vol.55, No.24, pp.1295–1297 (2019).

[10] 藤 聡子, 李 陽, 崎山一男, 菅原 健: 分光スペクトルを用いた LED の個体識別における電流変化の影響, 2019 年暗号と情報セキュリティシンポジウム (SCIS2019), 3D4-2, p.6 (2019).

[11] 藤 聡子, 土屋彩夏, 李 陽, 崎山一男, 菅原 健: 調光機能のある LED の個体識別, 2020 年暗号と情報セキュリティシンポジウム (SCIS2020), 3E1-3, p.6 (2020).

[12] Dyble, M., Narendran, N., Bierman, A. and Klein, T.: Impact of dimming white LEDs: Chromaticity shifts due to different dimming methods, *5th International Conference on Solid State Lighting, Proc. SPIE*, Vol.5941, pp.291–299, Bellingham, WA, International Society of Optical Engineers (2005).

[13] Keeping, S.: LED Color Shift Under PWM Dimming, Digikey Article Library, available from (<https://www.digikey.jp/en/articles/led-color-shift-under-pwm-dimming>) (2014).

[14] 長田正志, 田村将弘, 福澤茂和, 大西祥史: 物体指紋認証技術による個体識別機能の活用, NEC 技報, 新たな社会価値を生み出す AI 特集, Vol.72, No.1, pp.30–34 (2019).

[15] Hamamatsu: Mini-Spectrometer Micro Series C12666MA Datasheet (2019).

[16] Schubert, E.F.: *Light-Emitting Diodes, 2nd Edition*, Cambridge University Press (2006).

[17] 大武寛和: 特集 LED 照明の最新状況とさらなる普及への課題, 期待と展望 6: LED 照明の調光技術と課題, 電気設備学会誌, Vol.32, No.1, pp.23–25 (2012).

[18] Plank, H., Holweg, G., Steger, C. and Druml, N.: Time-of-Flight Based Optical Communication for Safety-Critical Applications in Autonomous Driving, *Computer Safety, Reliability, and Security (SAFECOMP2016)*, pp.183–194 (2016).

[19] アイリスオーヤマ: LED シーリングライト CL6DL-N1 (6 畳用・調光・調色タイプ), 入手先 (https://www.irisohyama.co.jp/led/ceiling/cl6dl_n1.html) (参照 2021-03-19)

付 録

A.1 機械学習アルゴリズムのパラメータ

5.6 節で述べたように、識別はグリッドサーチによるパ

表 A.1 各機械学習アルゴリズムで最終的に用いたパラメータ一覧
 Table A.1 Post-tuning parameters for each machine learning algorithm.

識別器	パラメータ
K-Nearest Neighbor	n_neighbors=1, leaf_size=10
Perceptron	alpha=1e-5, tol=1e-6
Logistic 回帰	C=10, solver="newton-cg", max_iter=1000
GaussianNB	var_smoothing=1
Decision tree (分類)	criterion="entropy", max_depth=150
Random Forest (分類)	n_estimator=90, criterion="entropy", max_depth=50, bootstrap=False
Multilayer perceptron	hidden_layer_sizes=1000, activation="tanh", solver="sgd", learning_rate="adaptive", learning_rate_init=0.01,
Support Vector Machine (分類)	C=1e-2, kernel="linear"
Adaptive Boosting	base_estimator=DecisionTreeClassifier(max_depth=9), learning_rate=0.5, n_estimators=100

ラメータチューニングを行った。表 A.1 に、最終的に得られたパラメータを示す。なお、表記していないパラメータについてはデフォルトで利用している。



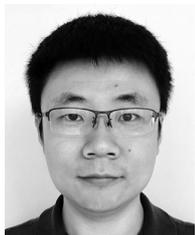
藤 聡子

2019 年電気通信大学情報理工学部卒業。2021 年同大学大学院修士課程修了。同年日本電気株式会社に入社。



土屋 彩夏

2020 年電気通信大学情報理工学域卒業。現在、同大学大学院修士課程在学中。



李 陽

2008 年 8 月中国ハルビン工程大学電子情報工学卒業。2011 年 3 月電気通信大学大学院電気通信学研究科博士前期課程修了。2012 年 12 月同大学院情報理工学研究科博士後期課程修了。2013 年 1 月電気通信大学産学官連携研究員。同年 4 月電気通信大学特任助教。2015 年 4 月中国南京航空航天大学准教授。2018 年 3 月電気通信大学准教授。暗号実装安全性評価の研究に従事。博士 (工学)。



崎山 一男 (正会員)

1994 年大阪大学基礎工学部電気工学科卒業。1996 年同大学大学院修士課程修了。同年 (株) 日立製作所入所。2003 年カリフォルニア大学ロサンゼルス校電気工学科修士課程修了。2007 年ルーベン大学電気工学科博士課程修了。2008 年電気通信大学准教授。2013 年より同教授。現在に至る。博士 (工学)。国際暗号研究学会 (IACR), IEEE 各会員。



菅原 健

2011 年東北大学大学院博士後期課程修了。博士 (情報科学)。2011 年より三菱電機株式会社情報技術総合研究所に入所。IC カード・車載機器・産業機器等の組込機器セキュリティに関する研究開発に従事。2017 年より電気通信大学准教授。2019 年には客員研究員としてミシガン大学に滞在。暗号実装、サイドチャネル攻撃、アナログサイバーセキュリティ等の研究を行う。