

論文 / 著書情報
Article / Book Information

題目(和文)	機械学習による電子写真プロセスの温度予測法の開発
Title(English)	
著者(和文)	長谷岳誠
Author(English)	Takamasa Hase
出典(和文)	学位:博士(工学), 学位授与機関:東京工業大学, 報告番号:甲第12525号, 授与年月日:2023年9月22日, 学位の種別:課程博士, 審査員:笹部 崇,岡村 哲至,奥野 喜裕,西田 佳史,伏信 一慶
Citation(English)	Degree:Doctor (Engineering), Conferring organization: Tokyo Institute of Technology, Report number:甲第12525号, Conferred date:2023/9/22, Degree Type:Course doctor, Examiner:,,,,,
学位種別(和文)	博士論文
Type(English)	Doctoral Thesis

東京工業大学 令和5年度 博士論文

機械学習による電子写真プロセスの温度予測法の開発

指導教員 伏信 一慶 教授

工学院 機械系 機械コース

長谷 岳誠

目次

第1章 緒論	1
1.1 研究背景	1
1.1.1 印刷技術の分類	1
1.1.2 印刷産業の市場動向	2
1.1.3 デジタル商用印刷の動向	3
1.1.4 電子写真方式デジタル商用印刷の付加価値	3
1.1.5 電子写真方式の概要	7
1.1.6 電子写真方式の原理	7
1.1.7 定着プロセスの原理	8
1.1.8 定着プロセスに関連する技術課題	11
1.1.9 定着技術課題に関する従来の研究	15
1.2 研究の目的	17
1.3 参考文献	19
第2章 機械学習を用いた電子写真プロセスにおける紙温度予測	21
2.1 緒言	21
2.2 FNNによる排紙部紙温度予測	21
2.2.1 実験装置	21
2.2.2 紙種と紙物性	23
2.2.3 機械学習アルゴリズム	24
2.2.4 実験条件	25
2.2.5 結果と考察	26
2.2.5.1 入力に紙厚を追加した排紙部紙温度予測モデル	28
2.2.5.2 入力に紙厚を追加した排紙部紙温度予測モデル	31
2.2.5.3 入力に紙厚, 平滑度を追加した排紙部紙温度予測モデル	33
2.2.5.4 過学習の検証	35
2.2.6 特許出願	36
2.3 LSTMによる排紙部紙温度予測	39
2.3.1 実験装置	39
2.3.2 紙種と紙物性	40
2.3.3 排紙部紙温度予測に用いたLSTMモデル	40
2.3.4 実験条件	41
2.3.5 排紙部紙温度の学習, 予測手順	44
2.3.6 結果と考察	44

2.4 機械学習による紙物性予測	45
2.4.1 実験装置	46
2.4.2 紙種と紙物性	47
2.4.3 機械学習アルゴリズム	47
2.4.4 実験条件	48
2.4.5 結果と考察	49
2.4.6 特許出願	52
2.5 結言	55
2.6 参考文献	57
 第3章 機械学習と熱回路網法による紙温度予測	 58
3.1 緒言	58
3.2 実験装置	59
3.3 紙種と紙物性	59
3.4 実験条件	62
3.5 熱回路網モデル	63
3.6 紙熱物性値予測のための ML アルゴリズム	66
3.7 従来手法による紙の熱物性値予測	68
3.8 結果と考察	70
3.9 結言	80
3.10 参考文献	81
 第4章 機械学習と熱回路網法によるトナー溶融性予測	 82
4.1 緒言	82
4.2 実験装置	84
4.3 紙種と紙物性	85
4.4 実験条件	86
4.5 熱回路網モデル	86
4.6 トナー溶融特性	87
4.7 定着温度範囲予測のための ML アルゴリズム	89
4.8 従来手法によるトナー，紙の熱物性	90
4.9 結果と考察	91
4.10 結言	95
4.11 参考文献	97

第 5 章 結論	98
付録	100
記号一覧	101
研究業績	102
謝辞	103

第1章 緒論

1.1 研究背景

1.1.1 印刷技術の分類

現在の印刷技術は、Fig. 1-1 に示すとおり、大きくアナログ印刷、デジタル印刷の2つの種類に分類される[1-1]。アナログ印刷は、有版印刷とも呼ばれ、刷版と呼ばれる複製用の版を作成し、色材を塗布して繰り返し紙などの記録媒体に転写する印刷技術であり、オフセット印刷、グラビア印刷、フレキソ印刷、スクリーン印刷がある。刷版の形状は、それぞれ平版、凹版、凸版、孔版である。これらの方式の中で、オフセット印刷は印刷業界の圧倒的なシェアを占めており、写真や色の再現性に優れた高品質な印刷物を大量に印刷する場合に適している。

それに対し、刷版を必要としないデジタル印刷としては、電子写真方式（トナー方式）、インクジェット方式が二大デジタル印刷技術として実用化されている。電子写真方式は、主にオフィスで利用されているレーザプリンタや複写機に使われている技術であり、感光体上に静電潜像を形成し、潜像に着色粒子であるトナーを静電的に付着させて顕像を形成し、これを紙に転写、定着させて画像を形成する。様々な紙種、メディアに対して高画質な画像を高速に印刷することが可能であるが、印刷プロセスが複雑であり、またトナーを加熱し、紙へ定着させる定着プロセスでの消費電力が大きい。

インクジェット方式は、液体インクをプリントヘッドのノズルから微細な液滴として吐出させ、紙に付着させる方式であり、家庭用小型プリンタ、オフィス向け複合機、産業用プリンタまで幅広く使われている技術である。構造がシンプルであり、インクジェット専用紙に対しては高解像度の印刷が可能であるが、普通紙に対してはインクの滲みや紙の波打ちが発生する。




Fig. 1-1 主要な印刷技術の分類[1-1]

1.1.2 印刷産業の市場動向

Fig. 1-2 は近年の国内一般印刷市場規模の推移である。2020 年度、2021 年度は、新型コロナウイルス感染拡大の影響やデジタル化、ペーパーレス化に伴い、印刷需要が減少傾向にある[1-2]。Fig. 1-3 は、国内デジタル印刷市場の推移を示している。2020 年度の国内デジタル印刷市場においても、新型コロナウイルス感染症拡大に伴う外出自粛の影響により販促需要が減少したことで市場規模が減少している。一方、コロナ禍で実施された様々な経済対策やワクチン接種券などに関する需要を取り込んだ市場が拡大し、2020 年度のデジタル印刷市場（事業者売上高ベース）は 3,097 億円とほぼ横ばいで推移し、コロナ禍でも市場規模を維持している。2021 年度は経済活動が再開される中で回復してきており、2022 年度のデジタル印刷市場は 3,290 億円増加する予測となっている[1-3]。



単位：百万円、%									
	2013年度	2014年度	2015年度	2016年度	2017年度	2018年度	2019年度	2020年度 (見込)	2021年度 (予測)
市場規模	3,611,807	3,573,725	3,572,074	3,531,727	3,494,057	3,453,199	3,439,091	3,194,000	3,074,000
前年度比	-	98.9	100.0	98.9	98.9	98.8	99.6	92.9	96.2

注1. 事業者売上高ベース


注2. 2020年度は見込値、2021年度は予測値

注3. 出版印刷、商業印刷、証券関連・カード印刷、ビジネスフォーム印刷の4つの分野を総称して、一般印刷市場とする。

印刷・加工高に加え、デジタルサービスや付帯サービスなどの関連サービス売上高も含み、ビジネスフォーム印刷にはDPS・BPO市場も含む。

矢野経済研究所調べ

Fig. 1-2 国内一般印刷市場規模の推移[1-2]



注1.事業者売上高ベース

矢野経済研究所調べ

注2.2021年度見込値、2022年度予測値

注3.商業用デジタル印刷機で印刷された印刷物、及び付帯サービスで構成された市場をさし、印刷業を主な事業として展開している事業者を対象とする。

但し、有版の印刷機による印刷物、及び付帯サービスは含まない。一般印刷分野(出版印刷、商業印刷、ビジネスフォーム印刷など)、軟包装・紙器印刷(パッケージ印刷)分野を対象とした。

Fig. 1-3 デジタル印刷市場規模の推移[1-3]

1.1.3 デジタル商用印刷の動向

従来の大量印刷から、顧客需要の多様化、小ロットの印刷へ需要がシフトしていることは、印刷業界の市場規模が縮小しているにも関わらず、デジタル印刷市場が大きく減衰していない要因と考えられる。「印刷業界におけるデジタル印刷に関するアンケート調査[1-4]」によると、顧客へのデジタル印刷のアピールポイントは、「極小ロット」が最も多く、「短納期」、「1枚1枚内容を変えた印刷ができる」、「必要なときにすぐ提供できる」、「在庫レス」、「エコロジー（無駄な廃棄がない）」、「1部単価の安さ」と続く（Fig. 1-4）。デジタル印刷機保有企業としての有版印刷に対するデジタル印刷のメリットは、「オペレータが確保しやすい」が最も多く、「自動化・省人化が容易」、「収益性が高い（高付加価値）」と続く（Fig. 1-5）。オフセット印刷は高品質であるが、色調整の習熟には長い期間が必要となる。一方で、現在主力の電子写真方式（粉体トナー方式のデジタル印刷）は、ある一定レベル以上の品質の印刷であれば短期間に習熟が可能であるとともに、自動化も可能である。また、必要な枚数だけ印刷して無駄な廃棄を減らすことは、コスト面だけでなく、社会的に環境対応を強く求められていることから必要不可欠である。




Fig. 1-4 デジタル印刷の顧客への訴求ポイント[1-4]




Fig. 1-5 デジタル印刷が有版印刷よりも有利な点[1-4]

1.1.4 電子写真方式デジタル商用印刷の付加価値

電子写真方式デジタル商用印刷が提供する前節以外の付加価値としては、スペシャルカラーによる誘目性を高める効果が挙げられる。RICOH Pro C7200S シリーズでは、オプションとして5色目トナーを、ネオン、イエロー、ネオンピンク、ホワイト、クリア、ゴールド、シルバー、インビジブルレッドの7色展開している[1-5]。Fig. 1-6, Fig. 1-7, Fig. 1-8, Fig. 1-9にRICOH Pro C7200Sで印刷されたサンプルを示す。Fig. 1-6は文字や写真の上にクリアートナーを印刷することで、画

像に光沢を付与している。Fig. 1-7 はメタリックペーパー、Fig. 1-8 はブラックペーパーの上にホワイトトナーを印刷しており、通常トナーでは不可能な特殊効果を得ることが可能である。Fig. 1-9 (a) はクリアファイル、(b) は耐水シール紙への印刷であり、電子写真方式は紙以外の多種多様なメディアにも特殊な処理をせずに印刷が可能である。様々な顧客需要に基づいて印刷物を提供する際、画像だけでなく紙についても様々な要求に応える必要がある。薄紙の広告、伝票から、厚紙のカタログなどとともに、紙サイズや紙表面加工についても要求が異なる場合がある。このような紙種への要求に対しても、現在主力の電子写真方式は、インクジェット方式よりも幅広く対応可能である。



Fig. 1-6 クリアートナーによる光沢付与



Fig. 1-7 メタリックペーパーへのホワイトトナー印刷



Fig. 1-8 ブラックペーパーへのホワイトトナー印刷



(a) クリアファイル



(b) 耐水シール紙

Fig. 1-9 特殊紙への印刷

1.1.5 電子写真方式の概要

以上のように、電子写真方式は他の印刷方式と比較し、多品種・小ロットの印刷に適している、特殊印刷が可能、紙種対応力に優れている、などの特徴を有している。本章では、電子写真方式の基本技術、技術課題、従来研究について詳細に記述する。

電子写真方式は、1938年にカールソン (Chester F. Carlson, 1906-1968) により発明され[1-6]、1940年に電子写真のプロセスが自動化された自動複写機の特許が出願された[1-7]。これが電子写真方式の原型となり、1959年にはこれをもとに全自動複写機が発売されている。商品に利用されるようになった電子写真方式はその後事務用複写機などへの利用が広がっていき、現在の商用印刷など様々な分野で用いられている。

1.1.6 電子写真方式の原理

電子写真方式は、光導電現象を利用して感光体上に静電的な電荷の画像（静電潜像）を形成し、さらに着色された帯電微粒子（トナー）を静電力で静電潜像に付着させて、可視像とするプロセスである[1-8]。電子写真方式はFig. 1-10に示すように1. 帯電, 2. 露光, 3. 現像, 4. 転写, 5. 定着の計5つのプロセスから構成され、画像を形成する。各プロセスの概要を以下に示す。




Fig. 1-10 電子写真方式の基本構成，画像形成プロセス

1. 帯電

帯電ローラやコロナ放電器などの帯電器を用いて、感光体ドラムを一様に帯電させる。

2. 露光

帯電した感光体ドラムに画像情報に基づいてレーザで静電潜像を形成する。

3. 現像

静電気力によって静電潜像にトナーを付着させる。

4. 転写

感光体表面に付着させたトナー像を静電気力により転写紙に転写させる。

5. 定着

転写紙に転写れたトナーを熔融させ、紙に固着させる。この定着プロセスは本研究で主に扱うプロセスであるため、次節以降で更に詳細を記述する。

1.1.7 定着プロセスの原理

電子写真方式のプロセスの 1 つである定着プロセスの原理について記載する。定着プロセスはトナーを紙に固着させるプロセスである。定着プロセスの前工程、転写プロセスにおいてトナーは静電気力により感光体から印刷対象の紙に転写される。そして、トナーに熱と圧力を与えて紙に定着される。現在多く使われている電子写真方式の定着プロセスは、Fig. 1-11 に示すように加熱された定着ローラ（上側）と加圧ローラ（下側）が圧接して定着ニップと呼ばれるトナーに熱と圧力を与える領域を形成する熱ローラ方式を基本とする方式が主流である。




Fig. 1-11 定着プロセス[1-8]




Fig. 1-12 トナーの動的弾性率と定着ラチチュード[1-8]

Fig. 1-12 は、トナーの温度に対する動的弾性率の変化を示している。トナーは定着ニップ内で加熱され、ガラス転移温度を超えるとゴム状領域となり、更に高温になると流動域となる。Fig. 1-12 では、ゴム状領域は白黒定着域、流動域はカラー定着域と明確に分けられており、過去の機種ではモノクロ画像は低温領域、カラー画像は高温領域で使われていたが、近年はカラー機において、ウォームアップ時間の短縮や環境対応が求められ、より低温で定着する必要があることから、低温で溶融するトナーが開発され、モノクロ、カラーの定着温度範囲は一致するように設計されていることが多い。

熱ローラ方式で発生する現象の一つとして、トナーの一部が定着ローラに転移するオフセットと呼ばれる現象がある。低温領域で発生するオフセットはコールドオフセット、高温領域で発生するオフセットはホットオフセットと呼ばれる。定着ラチチュード（定着温度範囲）とは、どちらのオフセットも発生しない温度範囲であり、コールドオフセットが発生しなくなる定着下限温度から、ホットオフセットが発生する定着上限温度を指す。

オフセットの発生メカニズムは、Fig. 1-13 に示すとおり、ニップ内部で働く 3 つの力の釣り合いで表すことができる。

- f_1 : トナーとローラの付着力
- f_2 : トナーの凝集力
- f_3 : トナーと紙の付着力

コールドオフセットは、トナー溶融が十分でないため、トナーと紙との付着力 f_3 がトナーとローラの付着力 f_1 より小さい場合に発生する。ホットオフセットは、トナーの弾性率が低下し、トナー同士の凝集力 f_2 がトナーとローラの付着力 f_1 より小さくなり、トナー層内で分断して定着ローラにオフセットする現象である。




Fig. 1-13 ニップ内の力の釣り合い[1-8]

トナーの紙への定着メカニズムは、接着剤と同様と考えることができる。Fig. 1-14 に示すように、接着力は物理的作用力、化学的作用力、機械的結合力に分けられる。トナーが紙に接着するためには、分子間力が発生するまで接近するために液体であり、紙とはよく濡れることが必要となる。その後、固化して接着が完了する。普通紙は多孔質体であるため、溶融トナーの浸透による機械的結合力も発

生するが、物理的作用力が基本原理である。




Fig. 1-14 接着理論[1-8]

次に、現在の主要な定着装置の構成について記述する。Fig. 1-15(a)はローラ定着の概要図である。この方式は、加熱された定着ローラと、加圧ローラによって加圧された接触部である定着ニップに紙とトナーを通過させることで、定着ローラ表面から伝導される熱エネルギーと圧力によってトナーを定着させる方式である。トナーを定着させるためには、100℃以上の表面温度と、数mm～10数mmのニップ幅と、 $0.5 \sim 10 \times 10^5$ Paの圧力が必要である。ローラ内部にはハロゲンヒータなどの加熱源を有し、少なくとも定着ローラと加圧ローラの一方は弾性層を有し、両ローラを荷重で押し付けて弾性変形してニップが形成される。また、ローラの表面は直接トナーと接触するため、トナーの一部がローラ表面に転移するオフセット現象を防止するために、定着ローラの表面に離型層を設け、さらにシリコンオイルなどの離型剤を塗布する場合もある。

Fig. 1-15(b)はベルト定着の概要図である。ベルト定着は定着ローラと加熱ローラの周りに定着ベルトを張架した構成である。定着ニップは、定着ベルト内部の定着ローラと、加圧ローラとの圧接により形成される。この方式の特徴は加熱部と定着部が分離している点である。定着ベルトと加熱する加熱ローラとともに熱容量を小さくできるため、ウォームアップ時間を短縮できる。また、定着ニップ部と加熱部が分離しており、厚い弾性層を有するローラを使えるので、比較的大きなニップ幅を得ることができ、高速化が可能である。




Fig. 1-15 主な定着装置の構成[1-8]

Table 1-1 電子写真装置の定着プロセスに関連する技術課題[1-9]

電子写真装置の定着技術		
対象技術分野：課題と要素技術		
環境対応技術	高速化対応技術	高画質対応技術
省エネルギー 使用時消費電力削減 待機時消費電力削減(起動時間短縮) 熱容量の低下 ほかの箇所への熱の利用 省資源 耐久性向上、損傷防止 小型化・軽量化 消耗材、消費剤削減 環境への影響削減 騒音対策 有害物質対策 フリッカー対応・周辺機器対応	高速定着⇔省エネルギー技術、高画質技術 高速加熱 加熱方式 定着方式 熱伝導面積増加(ワイドニップ) 低温定着(トナー関与) 定着条件制御 最大定着速度(トナー量、紙種等) 紙の搬送性向上⇔高画質技術 剥離性 起動時間短縮⇔省エネルギー技術 定着装置の低熱容量化 加熱装置・方式	温度の均一化(温度制御) 圧力の均一化(圧力制御) ニップ幅の増加 オフセットの防止 光沢制御 カラー対応 クリーニング性能向上(含む、汚れ防止) 画質低下の防止 画像の保存性・耐久性

1.1.8 定着プロセスに関連する技術課題

近年の電子写真方式の定着プロセスに関連した技術課題について考察し、本研究で対象とすべき技術分野について検討する。Table 1-1 は定着技術に関連する特許出願技術動向を示したものである[1-9]。定着技術課題は、環境対応、高速化対応、高画質対応に大きく分類されている。


環境対応としては、更に省エネルギー、省資源、環境への影響削減に分類される。電子写真装置の工程の中で定着プロセスの消費電力は全体消費量の約 2/3 を占め、消費電力の削減は定着技術において重要な課題の 1 つである。国際エネルギースタープログラム[1-10]は、オフィス機器の国際的省エネルギー制度であり、製品の消費電力などについて米国 EPA (環境保護庁) により基準が設定され、この基準を満たす製品に国際エネルギースターロゴの使用が認められている。本制度の基準として使用される値は、TEC=Typical Electricity Consumption (標準的な電力消費) として規定され、プリンタ、複合機を、規定された印刷モードで動作した積算電力量が TEC 値となる。有害物質に関する認定基準としては、ドイツで最初に導入されたブルーエンジェルがある[1-11]。プリンタ等の事務機器から放散される微粒子の排出量に関する基準が定められている。

Table 1-1 は、定着技術としてまとめられ、定着装置内での課題を中心に記述されているが、定着プロセスが引き起こす熱に関する課題を、定着装置内のみの課題と、複合機・プリンタのシステム全体に影響する課題とに分けることもできる。

高速化対応としては、定着プロセスに限れば、低温定着トナーの開発や、定着装置の低熱量化による加熱効率アップが主に挙げられているが、高速化に伴って定着プロセス通過後に紙が冷却されず、搬送中に機内温度を上昇させる課題もある。

Fig. 1-16 は、連続印刷において定着プロセス通過後に温度上昇した紙が MFP 機内を搬送され、機内温度上昇を発生させたときの温度分布のシミュレーション結果である[1-12]。MPF 機内には複数の熱源が存在するが、定着装置が最も高温になり、そこから排紙される紙も高温になり、特に両面印刷では搬送経路が長くなるため、機内温度上昇が悪化しやすくなる。また、高速化印刷、大量印刷の場合においては、紙や機内の冷却が十分でない場合がある。特に定着装置以外のトナーが存在する箇所

の冷却は重要であり、トナーは所定温度以上になると凝集してトナー搬送性を悪化させたり、異常画像を引き起こすことがある。また、省エネルギー性向上のためのトナーの低融点化に伴い、トナー凝集が発生する温度も低くなりやすい。



(a) 片面印刷時

(b) 両面印刷時

Fig. 1-16 MFP 機内温度シミュレーション結果[1-12]




Fig. 1-17 排紙部におけるトナーブロッキングの発生例

上記以外にも、高速化と高画質のどちらにも関連する課題として、トナーブロッキングが挙げられる。前節で記述したとおり、定着プロセスでは紙に付着したトナーに熱を与えて溶融させた後、再度

固化させてトナーを紙に固着させている。このとき、印刷速度が速い場合、紙搬送過程において紙温度を十分に下げられず、トナーが固化しないまま印刷機から排紙される。こうして固化しないままのトナーが付着した紙が排紙トレイに重ねられると、画像（トナー）同士が貼り付いた状態で固まる現象が発生し、これをトナーブロッキングと呼ぶ。トナーブロッキングは特に両面印刷で発生しやすく、Fig. 1-17 に示すように、貼り付いた紙同士を剥がす際に、画像（トナー）が、反対側の紙や画像へ転移する場合がある。トナーブロッキングを防ぐためには定着プロセス通過後の紙を十分に冷却する必要がある、これが印刷の高速化の1つの妨げとなっている。




Fig. 1-18 冷却搬送装置の一例[1-13]

トナーブロッキングを防止するため、これまで、紙を冷却する手段が種々考案されてきた。Fig. 1-18 は、冷却搬送装置の概略の一例である。冷却搬送装置は電子写真プロセスの下流に配置、もしくは電子写真作像装置本体に外付けされ、紙を冷却するためのU字状板金の搬送経路と、搬送経路の板金を冷却するため外気を吸引する吸気ファン（上面と底面）と、冷却搬送装置内の空気を装置の外に排出する排気ファン（紙面から見て冷却搬送装置の背面）を有する。定着プロセスで加熱され、搬送されてきた紙は、冷却用の搬送経路の板金に接触しながら搬送されることで、温度が低下する。紙通過により温度上昇した冷却搬送装置の搬送経路の板金は、吸気ファンからの風を受けて冷却され、紙の冷却効果を保持するように設計されている。すなわち、十分な間隔を持って紙が次々と搬送される限り、吸気ファンによる風により板金が冷却されるので、板金はトナーブロッキング現象が発生しない程度に紙を冷却することができる。このような冷却装置は紙冷却に対して効果的であるが、ファンから発生する騒音や冷却装置を外付けすることによる大型化といった課題も生じる。これらの課題と、紙冷却を両立させるように冷却装置の構造やファン出力を設計する必要がある。

また、定着装置内での課題においては、Table 1-1 の高画質対応技術の中に、「オフセットの防止」

がある。前節でメカニズムを記述したとおり、オフセット、特にコールドオフセットとは、画像上のトナーが溶融不足により紙との接着力が不足し、定着ベルト、または定着ローラへ転移する現象のことである。商業印刷では前節で述べたように様々な紙種需要がある。Fig. 1-19 は坪量（紙の単位面積当りの質量）はほぼ同一であるが、表面コーティングの有無の差がある。Fig. 1-19(a)はコート紙、(b)は普通紙である。コート紙は表面にコーティングが施され、平滑になっている。どちらも同じ定着温度、同じ印刷速度で印刷したが、(a)コート紙は問題無く定着し、(b)普通紙はコールドオフセットが発生した。このように同じ坪量の紙であっても、表面が異なると定着性が大きく異なり、商用印刷では紙銘柄ごとに最適な定着条件を設定している場合がある。



(a) コート紙

(b) 普通紙

Fig. 1-19 紙種ごとの定着性の違い

多種媒体に対して、高速、高画質を実現した技術も開発されている。従来は、厚紙でのトナー定着性を確保するため、印刷速度を落として十分に加熱し、コールドオフセットが発生しないように制御していた。しかし、imagePRESS C7000VP は、坪量 64 g/m^2 の普通紙から、 300 g/m^2 の厚紙まで同一の印刷速度を実現した[1-14]。Fig. 1-20 に示すように、定着装置は第一定着と第二定着のデュアル定着システムで構成され、第一定着では、加圧ベルトによるワイドニップによりトナー加熱時間を長くし、厚紙でもコールドオフセットが発生せずに高速印刷が可能となっている。第二定着は、厚紙のみが十分な定着性、画像光沢を得るために通過し、 150 g/m^2 以下の紙は第二定着を通過しない。




Fig. 1-20 imagePRESS C7000VP に搭載のデュアル定着システム[1-14]

1.1.9 定着技術課題に関する従来の研究

前節での課題も含め、これまでに電子写真方式における定着プロセスや、定着装置起因の MFP 内の温度上昇に関連した熱課題について、多くの解析や研究が行われてきた。

大杉らは、試作レスによる開発効率改善を目的とした MFP 機内の熱と気流の解析モデルを構築した[1-12]。MFP 機内は部品が数千～1 万点ほど搭載され、定着装置以外にも駆動部や電源など複数の熱源が存在し、臭気や微粒子の除去や、部材冷却のための気流形成、定着で加熱された紙の搬送などにより、機内は複雑な伝熱現象となり、機内温度分布を正確に予測することは容易ではないが、大規模かつ詳細な CAD モデルを簡略化せずに取り込み、さらに紙やベルトなどの移動体が熱を輸送する影響まで考慮した熱流体モデルを構築した。Fig. 1-16 に示すように、片面印刷の場合と、搬送経路が長くなり機内温度上昇への影響が大きい両面印刷の場合とで、それぞれ機内温度がどのように分布するかについて、高精度なシミュレーションを行った。

秋山は、MFP 筐体内の熱解析に対して CAE ツール等を用いて全領域を解析対象とするのは計算コストが高いため、エンジンモジュールの局所的な温度上昇と、筐体全域の排熱量に特化して計算を行った[1-15]。トナークリーナ部や、搬送時紙温度場などの物理モデル作成が困難な部位に対してはベース機による実験によって適用された経験モデルを用いた。一方で、紙や現像装置に対しては、計算モデルで明確に表現できていない。

百村らは、複写機内の熱設計のために CFD (Computational Fluid Dynamics) と熱回路網法を連携させて熱流解析を行った[1-16]。機内全体に CFD を適用する上での課題の一つに計算コストがあるが、それ以外に複写機特有の課題として、定着後の紙、中間転写ベルト、現像剤といった移動物体のモデル化の難しさがある。このような物体の移動に伴う熱輸送には熱回路網法を適用することで、実用的な精度と計算コストを両立させた。

以上の研究において、MFP やプリンタと、他の電子機器との大きく異なる点は、定着による紙の加熱、紙搬送による熱移動、トナー溶融に関する課題を扱っていることである。これらの現象を詳細に再現できるモデルは汎用の熱流体シミュレーションソフトウェアには組み込まれておらず、設計者自身により経験則などに基づいて必要な精度の解析モデルを構築する必要がある。

定着プロセスにおける紙、トナーへの伝熱現象の解析に関しては、以下の研究が行われてきた。

醒井らは、定着領域内部のトナー粒子や紙表面に存在する空気の伝熱抵抗をモデル化し、トナー粒子層温度を高精度に予測できる仮想空気層の構成について示した[1-17]。

植木らは、温度制御までを含む定着システム全体の三次元非定常熱伝導モデルを構築し、ヒータからヒートロール、紙への三次元的な伝熱解析を可能にした[1-18]。

森らは、CFD (数値流体力学) を定着器熱設計に適用し、ふく射の影響を考慮したモデルを構築し、定着器内部に設置した遮蔽板による省エネ効果と、定着器外部の温度上昇抑制効果を解析した[1-19]。

大西らは、定着ニップ内においてトナーが加圧、加熱変形して紙に定着する過程をシミュレーションし、紙の表面形状が定着強度に対してどのような影響を及ぼすのかを明らかにした[1-20]。

加藤らは、トナーと定着部材間の付着力を考慮し、トナーと定着部材の剥離過程の計算を可能にし、定着器におけるホットオフセットの予測方法を提案した[1-21]。

北沢らは、三次元計算による計算負荷を軽減するため、定着器の構成部材の接触による熱移動を事前解析で関数化する手法を用いて簡易化、高速化し、実機同様の温度変化を高速、高精度に予測できるシミュレーションツールを構築した[1-22]。

しかし、前述したように電子写真プロセスにおける熱解析には、紙とトナーをモデル化する必要があるが、近年の商用印刷ではメディアが多種になり、印刷条件も各メディアに応じて細かく設定されるため、モデル化を更に困難にしている。また、定着プロセスは数 10 ms の短時間で加熱されるが、定着プロセス後の冷却は数 s から数 10 s であり、紙の加熱から冷却まで複数の伝熱現象が異なる時間スケールで行われており、高精度の物理モデルを各メディアや印刷条件に応じて構築することには限界がある。

一方、近年新たなアプローチとして機械学習を用いた設計の試みが行われている。及川らは、電子写真方式の商用印刷において、技術者が実施していた特殊媒体の印刷設定調整作業を AI を用いて自動化し、顧客に提供するための技術開発に取り組んでいる[1-23]。入力を①特殊媒体の情報、②印刷不良画像の特徴量、③印刷不良発生時の印刷設定とし、教師データを印刷不良を解消できる印刷設定値として学習させ、予測モデルを構築する (Fig. 1-21)。顧客先で画像不良が発生した場合には、自動で最適な印刷設定値に変更する。このような仕組みを活用することにより、従来よりも短期間の印刷不良解消が可能となる。




Fig. 1-21 機械学習による印刷設定の自動調整[1-23]

1.2 研究の目的

以上の背景を踏まえて、本研究の目的について記述する。電子写真方式の商用印刷において、今後は印刷速度の高速化と多種多様なメディア対応が付加価値として拡大していくと考えられる。それに伴い、特に Table 1-1 で記述した定着プロセス起因の熱課題についても多種多様になると考えられ、製品設計段階で対策や予測を盛り込み、実用性、信頼性のある商品を開発する必要がある。システム課題の中で、トナーブロッキングは高速化、高画質化のどちらにも関連し、また、多種多様なメディアに対しては温度上昇も異なるため、予測や対策が難しい。そして、多種多様なメディアに対する定着プロセスの最適な条件は異なり、メディアごとの印刷設定が必要となる。従来は、紙種ごとに最適印刷条件を評価するか、紙種カテゴリーごとに印刷条件を設定していたが、商用印刷における膨大な紙種は評価工数も膨大となり、過剰な加熱はトナーブロッキングや環境性能を悪化させ、また加熱が不十分であればコールドオフセットを引き起こす。これらの相互に関連する課題に対して、短い開発期間における予測、対策、設計には、従来の複雑な熱物理モデルによる解析ではなく、簡易かつ高精度にモデル構築が可能な機械学習が適していると考えられる。機械学習は、学習データに基づいてモデルを自動的に構築するアルゴリズムであり、多くのパラメータを持つため、高い自由度を持つことができる。

そこで、本研究では機械学習モデルを基本としたトナーブロッキングの予測手法と、定着プロセスのトナー定着性予測手法を開発することを目的とする。また、商用印刷機は工場出荷時に製品固体差が小さくなるように調整されるため、これらの課題に対する製品固体差は一般的に小さく、開発段階で学習をする手法を想定して開発する。

第2章では、トナーブロッキングの予測手段として、排紙部での紙温度を様々な紙種、印刷条件に対して、高精度に予測できる機械学習モデルを構築することを目的とする。第一の機械学習モデルとしては、一般的なFNN (Feedforward neural network) を用い、適切な入出力を選定して排紙部紙温

度の予測精度を確認する．第二の機械学習モデルとしては，LSTM（Long short-term memory）と呼ばれるニューラルネットワークを用いる．LSTM は時系列データを扱うことに優れ，入力の変化する時間変化に基づいた予測を行うことが可能である．FNN モデルでは未来の紙温度を予測することはできないが，LSTM モデルでは印刷開始後所定期間の温度データからその先に印刷される紙温度を予測することが可能となると考えられる．第三の機械学習モデルとして，紙物性を予測する機械学習モデルを構築する．印刷条件や紙の種類は多岐にわたり，市場で使用される紙種は数 100 種類以上になる機種もある．排紙部の紙温度を高精度に予測するためには，紙物性が必要となるが，市場での使用される全ての紙銘柄の特性値を取得することは容易ではない．紙の特性値を検知，判定できる装置も開発されているが，ある程度の実験データがあれば，機械学習を用いて予測することも可能と考えられる．そこで，印刷時における定着装置内のセンサ温度応答から紙物性を予測することを検討する．

第 3 章では，従来の熱物理モデルと機械学習を組み合わせ，少ない学習実験回数で，学習していない条件においても紙温度を予測することを目的とする．一般的に高精度な機械学習モデルを構築するためには予測したい条件範囲における学習実験が必要である．一方，従来の物理モデルは，学習実験は不要であるが，熱物性値の取得が必要であるとともに，測定誤差が大きい場合もある．しかし，機械学習によりモデルに適した熱物性値を予測し，従来の熱物理モデルに入力することで少ない学習実験により紙温度を予測できると考えられる．また，従来の物理モデルとの予測精度比較を行うことで，本研究で提案する手法の有効性を明らかにする．

第 4 章では，第 3 章と同様に従来の熱物理モデルと機械学習を組み合わせ，少ない学習実験回数で，学習していない条件においてトナーの定着温度範囲を予測することを目的とし，本研究の目的の一つであるコールドオフセットを発生させない定着温度範囲を複数の紙種に対して予測できる手法を開発する．

以上により，本研究では，製品開発，設計段階において，機械学習モデルを基本としたトナーブロッキングの予測と，定着プロセスのトナー定着性予測を行い，実用性，信頼性のある製品を開発することを目的とする．

1.3 参考文献

- [1-1] 宮本 泰夫, “インクジェットを中心としたデジタル印刷技術,” 日本印刷学会誌, 第 54 巻, 第 5 号, pp. 312-318, 2017.
- [1-2] 矢野経済研究所, “一般印刷市場に関する調査(2020 年),” https://www.yano.co.jp/press-release/show/press_id/2531.
- [1-3] 矢野経済研究所, “デジタル印刷市場に関する調査(2022 年),” https://www.yano.co.jp/press-release/show/press_id/2962.
- [1-4] 公益社団法人日本印刷技術協会, “印刷白書 2022” .
- [1-5] 早川 真一郎, “多品種・小ロット型印刷の需要と対応,” 日本印刷学会誌, 第 59 巻, 第 2 号, pp. 54-57, 2022.
- [1-6] Carlson, F. C., “ELECTROPHOTOGRAPHY,” USP 2297691. Filed, 1939.
- [1-7] Carlson, F. C., “ELECTROPHOTOGRAPHIC APPRATUS,” USP 2357809. Filed, 1940.
- [1-8] 日本画像学会, “電子写真-プロセスとシミュレーション-,” 東京電機大学出版局, 2008.
- [1-9] 特許庁, “特許出願技術動向調査報告書(概要) 電子写真装置の定着技術(2010),” https://warp.ndl.go.jp/info:ndl.jp/pid/10358553/www.jpo.go.jp/shiryou/pdf/gidou-houkoku/22densipt_tcgijutu.pdf.
- [1-10] 国際エネルギースタープログラム, <https://www.energystar.go.jp/about.html>.
- [1-11] ブルーエンジェル, <https://www.blauer-engel.de/de>
- [1-12] 大杉 友哉, 首藤 美和, “MFP 機内全体の熱・気流シミュレーション,” リコーテクニカルレポート, No. 39, 2014.
- [1-13] T. Ogawa, “Sheet Conveying Device, Print System, and Sheet Cooling Method,” U. S. Patent 8,596,637, 2013.
- [1-14] 太田 光弘, “多種媒体への高速・カラー高画質化技術への挑戦-imagePRESS C7000VP-,” 日本画像学会誌, 第 47 巻, 第 2 号, pp. 97-103, 2008.
- [1-15] 秋山 修, “MFP における熱解析の現状,” 日本画像学会誌, 第 43 巻, 第 3 号, pp. 186-192, 2004.
- [1-16] 百村 裕智, “熱回路網法と CFD の連携による複写機の熱流解析,” Imaging Conference Japan Spring Meeting 予稿集, pp. 23-26, 2010.
- [1-17] 醒井 政博, 下川 拓生, 竹之内 和樹, 川北 和明, “トナー定着プロセスにおける温度場の数値予測,” 日本画像学会誌, 第 38 巻, 第 1 号, pp. 26-34, 1999.
- [1-18] 植木 平吾, 三矢 輝章, 詫間 康夫, 片岡 篤, “流体モデルを用いた現像用器内シミュレーション・定着システムの熱解析,” 日本画像学会誌, 第 43 巻, 第 3 号, pp. 180-185, 2004.
- [1-19] 森 一浩, 市川 与志彦, “数値流体力学の定着器熱設計への適用,” 日本画像学会誌, 第 44 巻, 第 1 号, pp. 16-21, 2005.
- [1-20] 大西 拓馬, 加藤 恭平, 古井 貴昭, 依田 寧雄, “定着プロセスにおけるトナー変形シミュレーション,” 日本画像学会誌, 第 49 巻, 第 2 号, pp. 106-112, 2017.

- ュレーション(2),” Imagine Conference JAPAN 2011 論文集, pp. 245-248, 2011.
- [1-21] 加藤 恭平, 大西 拓馬, 河野 将希, 小原 泰成, 依田 寧雄, 志賀 俊樹, “定着プロセスにおけるホットオフセットのシミュレーション,” Imagine Conference JAPAN 2012 論文集, pp. 63-66, 2012.
- [1-22] 北沢 佳月, 伊藤 朋之, “ベルトニップ定着器熱設計のための伝熱シミュレーション,” Imagine Conference JAPAN 2011 論文集, pp. 253-256, 2011.
- [1-23] 及川 真史, 金井 邦夫, 嶋田 徹一, “インダストリープリントにおける AI を活用した特殊媒体印刷,” OKI テクニカルレビュー, 第 230 号, Vol. 84, No. 2, 2017.

第2章 機械学習を用いた電子写真プロセスにおける紙温度予測

2.1 緒言

前章で記述したように、商用印刷は多種多様な紙種、紙サイズ、特殊印刷など様々な印刷条件が存在し、更に、普通紙だけでなく特殊紙の印刷速度も向上している[2-1][2-2]。特殊紙の中にはトナーとの接着性が悪く、定着温度を引き上げることで十分にトナーを溶融させて定着させる紙種も存在する。更に、印刷速度向上に伴い、大量印刷時には機内や搬送経路の温度が上昇し、連続両面印刷された紙が排紙トレイ上でスタックされた際に、紙上のトナー同士が貼りつくトナーブロッキングが発生しやすくなる。

トナーブロッキング予測のために、川崎らは、従来の物理モデルを用いずに、機械学習によって商用印刷機の排紙部の紙温度を予測する方法を提案した[2-3][2-4]。

本章では、川崎らの提案した手法を基本とし、トナーブロッキングの予測手段として、排紙部での紙温度を様々な紙種、印刷条件に対して、高精度に予測できる機械学習モデルを構築することを目的とする。第一の機械学習モデルとして、FNN モデルを用い、適切な入出力を選定して排紙部紙温度の予測精度を確認する。第二の機械学習モデルとして、LSTM モデルを用い、入力の変化する時間に基づいた予測を行う。FNN モデルでは未来の紙温度を予測することはできないが、LSTM モデルでは印刷開始後所定期間の温度データからその先に印刷される紙温度を予測することが可能となると考えられる。第三の機械学習モデルとして、紙物性を予測する機械学習モデルを構築する。排紙部の紙温度を高精度に予測するためには、紙物性が必要となるが、市場での使用される全ての紙銘柄の特性値を取得することは容易ではない。そこで、印刷時における定着装置内のセンサ温度応答から機械学習を用いて紙物性を予測することを検討する。

2.2 FNN による排紙部紙温度予測

2.2.1 実験装置

本実験で用いる実験装置は、Fig. 2-1 に示す電子写真方式商用印刷機 RICOH MP C8002 の量産機であり、一部改造して用いた。実験装置は、給紙装置 (Paper feed unit)、現像装置 (Developing unit)、感光体 (Photoconductor unit)、転写装置 (Transfer unit)、定着装置 (Fusing unit)、ヒートパイプ (Heat pipe) から構成されている。ヒートパイプは紙冷却のために備えてあり、ヒートパイプの端部では放熱フィンと冷却ファンによる冷却が行われる。




Fig. 2-1 実験装置の概要図

Table 2-1 温度センサの測定対象，センサ種類

Sensor No.	Target	Sensor type
(1)	Heat roller	Radiation thermometer
(2)	Fusing roller	Radiation thermometer
(2)	Fusing roller sensor	Radiation thermometer
(3)	Pressure roller	Radiation thermometer
(4)	Outlet paper	Radiation thermometer

本実験の目的は、定着装置内の温度情報から、排紙トレイでのブロッキングを予測することであるが、排紙トレイにスタックされていく紙と紙との間の温度を、連続印刷中に継続して測定することは難しい。よって、本体排紙部から排紙トレイに搬送されている紙温度を測定し、代用値として用いた。スタックされた紙温度と、排紙部紙温度は相関があると考えられる。Fig. 2-1 に示すとおり、温度センサの測定対象は、定着装置の加熱ローラ（Heat roller）（1）、定着ローラ（Fusing roller）（2）、加圧ローラ（Pressure roller）（3）、排紙部の紙（Outlet paper）（4）の4箇所に設置した。温度センサの種類は放射温度計である。放射温度計は、センサ自体の温度によって検知温度に誤差が生じるが、センサ自体の温度を測定し、検出された温度をセンサ自体の温度で補正している。センサ（2）のみセンサ自体の検出温度信号も外部に引き出している。この温度は、定着装置内部の雰囲気温度でもあり、定着装置の蓄熱量や、定着装置よりも搬送方向下流側の搬送経路における雰囲気温度と相関がある。センサ（1）、（2）、（3）は、定着装置温度を制御するために量産機に搭載されていたものである。センサ（4）は、排紙部紙温度を測定するためのセンサであり、本実験のために設置された。温度センサの測定対象、種類の一覧を Table 2-1 に示す。

定着装置の動作について説明する。定着プロセスは、前章で記述したとおりトナーと紙に熱と圧力を加え、トナーを溶かし、紙に定着させるプロセスである。発熱源からの熱は、ヒートローラから定着ベルトに伝えられ、定着ベルトは回転しながら定着ローラと加圧ローラとの接触領域であるニップ部に移動する。トナーと紙がニップ部を通過するときに、トナーと紙に熱と圧力が加えられる。温度制御は、ヒートローラ温度を検知するセンサー（1）の温度が目標温度に追従するように制御される。本章で用いられる定着温度（Fusing temperature）とは、ヒートローラの目標温度であり、ヒートローラの温度は目標温度に追従するように制御される。ヒートローラ温度（Heat roller temperature）、定着ローラ温度（Fusing roller temperature）、定着ローラセンサ温度（Fusing roller sensor temperature）、加圧ローラ温度（Pressure roller temperature）は、各センサで検知した温度を意味する。

2.2.2 紙種と紙物性

本実験では、異なる印刷条件下での排紙部紙温度を予測することを目的として、Table 2-2 に示す坪量、厚さ、平滑度、表面コーティング有無の異なる 9 種類の A3 サイズの紙で実験を行った。これらの特性は、定着装置から紙への伝熱、紙の温度上昇、定着装置から排紙部における温度低下に影響を与える。

坪量とは、1 平方メートルあたりの紙の質量である[2-5]。紙厚は、マイクロメーターで測定された紙の厚さである[2-6]。紙厚を坪量で表すこともあり、紙厚と坪量は概ね相関性はあるが、紙種が異なると、これらは大きく異なる場合もある。平滑度とは、紙表面の平滑性を表す指標であり、ガラス板に紙を押し当て、紙とガラス板との隙間を一定量の空気が通過する時間で表し、平滑度の単位は秒 (s) である[2-7]。通過時間が短いほど空気が抜けやすいため、紙の凹凸が大きく、平滑性は低い。また、一般的に紙の平滑度が高いほど、表面の光沢度は高くなる。より高品質な質感を得るために、表面コーティングが施される場合があり、平滑度を高くするグロスコーティングと、平滑度を低くするマットコーティングがある。コーティング材は、炭酸カルシウムとバインダー樹脂の混合物である場合が多い。

Table 2-2 実験で用いた紙種と紙物性

Paper type	Basis weight [g/m ²]	Thickness [μm]	Smoothness [s]	Surface coating
A	53	66	82	Non-coated
B	81	94	95	Non-coated
C	156	184	40	Non-coated
D	100	102	788	Coated
E	161	171	731	Coated
F	68	91	47	Non-coated
G	128	149	50	Non-coated
H	133	139	777	Coated
I	127	145	102	Coated

2.2.3 機械学習アルゴリズム

Fig. 2-1 に示す実験装置で測定された温度を用いて排紙部紙温度を予測するため、Python プログラミング言語の公開されているライブラリ TensorFlow[2-8], Keras[2-9], Scikit-learn[2-10]を用いて ANN による機械学習 (ML) アルゴリズムを開発した。ANN の出力は連続的な温度であるため、この ANN は分類モデルではなく、回帰モデルとした。

多くの機械学習モデルと同様に、ANN の構成はモデルの性能に重要な影響を与える。本研究で使用した ANN の構成図を Fig. 2-2 に、ANN のパラメータを Table 2-3 に示す。本節の ANN は、相互に接続された多数のニューロンから構成されている。第 1 層は入力層であり、複数の入力がある。入力数は各モデルによって異なる。最後の層は出力層で、出力は 1 つである。中間の 3 層は隠れ層で、各層のニューロン数はそれぞれ 64, 45, 14 である。各ニューロンには活性化関数とバイアスが存在する。入力情報はネットワークを通して前方のみに伝搬される。




Fig. 2-2 ANN の構成

Table 2-3 ANNのパラメータ

Number of hidden layers	3
Number of neurons of each hidden layer	64, 45, 14
Activation function on hidden layers	ReLU
Activation function on output layer	Linear
Optimizer	Adam

最適化計算にはAdam[2-11]を使用した。活性化関数としては、隠れ層でRectified Linear Unit (ReLU)，出力層でlinear unitを用いた。ネットワークの層は、Kerasライブラリ[2-9]が提供するDense関数で形成した。損失関数として平均二乗誤差（MSE）を使用した。

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

ここで、 n はデータ数、 y_i と $\hat{y}_i$ はそれぞれ i 番目のデータに対する測定値と予測値である。なお、モデルの性能を評価する際には、MSEも使用した。また、決定係数 R^2 も予測値の誤差を評価するために使用した。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2)$$

2.2.4 実験条件

実験条件は、Table 2-4に示す20条件である。Exp. No. 1～16は学習実験であり、Exp. No. 17～20は検証実験である。検証実験は、学習実験とは異なる紙種、定着温度、印刷速度の組合せで行った。学習実験においては、定着温度は標準温度(Std.)、 ± 20 ℃、印刷速度は標準速度(Std.)、 -17% 、 -49% の中から選択した。検証実験においては、定着温度は ± 10 ℃、 ± 15 ℃、印刷速度は標準速度(Std.)、 -17% 、 -49% の中から選択した。ここでの印刷速度とは、紙が搬送される線速度であり、定着ベルト、ヒートパイプ、紙搬送ローラの周速度でもある。

実験の性質上、放射温度計で測定した生データには、機械学習に不要な情報が多く含まれているため、得られた実験データには前処理が必要となる。連続印刷における紙搬送においては、 n 枚目の紙と $(n+1)$ 枚目の紙の間における紙が通過していない期間に温度センサは紙ではなく紙搬送ガイド部の温度を測定する期間がある。また、紙先端が突入したタイミングでは、センサの応答性により検知精度が悪くなる。さらに、1枚通過の期間にも若干の温度変動がある。そのため、紙が通過していない期間のデータを削除し、また、紙が通過している期間の温度の平均化処理も実施した。

入力データの単位は温度以外も扱うため、データは0から1の間でスケーリング処理を実施した。機械学習が完了した後、データを元のスケールに戻し、学習実験、検証実験の精度を確認した。

Table 2-4 実験条件

Exp. No.	Paper type	Fusing temperature [°C]	Printing speed [mm/s]	Purpose
1	A	-20	Std.	Training
2	A	Std.	Std.	Training
3	A	+20	Std.	Training
4	B	-20	Std.	Training
5	B	Std.	Std.	Training
6	B	+20	Std.	Training
7	B	-20	-17%	Training
8	B	+20	-17%	Training
9	B	-20	-49%	Training
10	B	+20	-49%	Training
11	C	-20	Std.	Training
12	C	Std.	Std.	Training
13	D	-20	-17%	Training
14	D	+20	-17%	Training
15	E	-20	-49%	Training
16	E	+20	-49%	Training
17	F	+10	Std.	Validation
18	G	-15	Std.	Validation
19	H	+15	-49%	Validation
20	I	-10	-17%	Validation

2.2.5 結果と考察

機械学習による予測結果を考察する前に、学習実験における各条件での排紙部紙温度の差について考察する。Fig. 2-3 は、学習実験における Fig. 2-1 のセンサ (4) で測定した排紙部紙温度である。縦軸は 500 枚連続印刷時の 400 枚目から 500 枚目までの 100 枚平均温度であり、縦軸の 1 目盛りは 10 °C である。この結果より、最高温度と最低温度の差は 20 °C 以上であった。つまり、排紙部紙温度は、紙の種類、定着温度、印刷速度に大きく依存する。定着温度はニップ部で紙に与える熱量、紙温度とほぼ相関があるが、印刷速度が低い場合、定着装置のニップ部での加熱時間が長くなるが、定着装置から排紙部までの搬送時間、つまり紙温度が低下する時間も長くなるため、相関性が低い場合もある。例えば、No. 6 と No. 10 の定着温度は同じであるが、No. 10 の印刷速度は No. 6 より低

く、定着装置から紙へ与える熱量は多い。しかし、紙温度が低下する時間が長くなり、No. 10 は No. 6 と比較して排紙部の紙温度が 7 °C 低くなった。紙の種類も紙温度に影響を与える。No. 4 と No. 11 の定着温度と印刷速度は同じだが、紙の種類が異なるため、排紙部の紙温度は 9 °C の差があった。

このように、紙温度は定着温度、印刷速度、紙の種類に大きく依存することが確認された。商用印刷では、印刷に使用する紙の種類も多く、定着温度や印刷速度などの印刷条件も紙の種類に合わせて様々である。全ての条件においてトナーブロッキングの発生レベルを評価するには、多くの時間を要する。そこで、機械学習モデルに基づいて定着後、排紙部紙温度を予測することの有効性を以降で確認した。




Fig. 2-3 学習実験における排紙部紙温度

また、機械学習モデルに基づいて排紙部紙温度を予測する際に目標とする予測精度について検討した。Fig. 2-4 は、印刷時におけるヒートパイプ、加圧ローラ、排紙部紙温度の推移の例である。紙温度が 60 °C から 70 °C の間に上昇している期間が、1 枚の紙が通過している期間である。1 枚内の紙温度変動は、熱源を持たない加圧ローラ、ヒートパイプ、温度センサ[4]の応答性の影響を受ける。加圧ローラは紙先端側ほど温度が高く、ヒートパイプは紙後端側が高くなる。センサ検知温度は、紙侵入時に上昇するが、検知遅れが生じる。1 枚内で ±5 °C 程度の紙温度変動が生じており、機械学習による予測値は 1 枚の平均温度なので、本モデルにおいて ±5 °C の予測精度であれば妥当と考えることができる。排紙部にスタックされた状態では均熱化されて変動は小さくなるため、予測温度は 1 枚の平均温度とした。




Fig. 2-4 印刷時におけるヒートパイプ，加圧ローラ，排紙部紙温度の推移

2.2.5.1 排紙部紙温度予測モデル

排紙部紙温度を予測するために，Table 2-5 に示すように，定着装置の各センサ温度，印刷速度，紙特性値を入力，排紙部紙温度を出力として選択した．定着装置の温度，装置内部の雰囲気温度は紙温度に大きく影響を与えるため，入力として必要であるが，一方で，センサ数を増やすことはコストアップ，計算量増大になるため，できるだけ量産品のセンサを使うようにした．また，この機械学習モデルでは，紙特性値の中で坪量のみを入力とした．坪量は紙の厚さを示す指標として商品名の一部にも表示されることがあり，容易に扱えることから選択した．紙の熱容量と紙の坪量とは相関があると仮定し，紙温度を予測可能かどうかを検証した．

Fig. 2-5 は，Exp. No. 1～16 の学習実験による排紙部紙温度予測モデルの予測精度である．予測精度は，実測温度に対して，ほぼ $\pm 3^{\circ}\text{C}$ 以内であった．Fig. 2-6 は，Exp. No. 17～20 までの検証実験の予測精度である．予測温度と実測温度の差が最大 $\pm 9^{\circ}\text{C}$ であり，トナーブロッキングの発生を正しく予測するためには予測精度は低いと判断される．検証実験において Exp. No. 18 が最も予測誤差が大きく，次に Exp. No. 19 が予測誤差が大きかった．Exp. No. 17 は最も予測誤差が小さく， $\pm 5^{\circ}\text{C}$ 以下であった．

Table 2-5 排紙部紙温度予測モデルの入出力

Input	Output
Heat roller temperature	Outlet paper temperature
Fusing roller temperature	
Fusing roller sensor temperature	
Pressure roller temperature	
Printing speed	
Paper basis weight	




Fig. 2-5 排紙部紙温度予測モデルの学習実験の予測精度






Fig. 2-6 排紙部紙温度予測モデルの検証実験の予測精度


Fig. 2-7 は、検証実験における排紙部紙温度プロファイルである。横軸は印刷枚数である。500 枚の連続印刷において、10 枚ごとに実測温度と予測温度をプロットした。印刷開始直後はヒートパイプや紙搬送経路の温度が低いため、排紙部紙温度も低かったが、その後、徐々に紙温度が上昇し、50 枚目付近でヒートパイプのファンが動作して一時的に紙温度が低下し、その後は一定となった。予測誤差は、Exp. No. 18 が最も大きく $\pm 9^{\circ}\text{C}$ であり、印刷開始時に誤差が最も大きいことが確認された。印刷開始時はヒートパイプや紙搬送経路の温度変動が大きく、予測誤差が大きくなりやすい。一方、Exp. No. 19 は、印刷開始から 300 枚目以降の安定した期間において予測誤差が大きくなった。Exp. No. 19 で使われた Paper H は、入力した坪量以外の特性値が検証実験で使われた他の紙と異なり、紙温度に影響する紙の特性値の入力が不足していたことが予測精度の悪化要因と考えられる。




(a) Exp. No. 17



(b) Exp. No. 18



(c) Exp. No. 19



(d) Exp. No. 20

Fig. 2-7 検証実験における紙温度プロファイル

2.2.5.2 入力に紙厚を追加した排紙部紙温度予測モデル

Table 2-6 に示すとおり，紙の坪量に加え，紙厚を入力として加えたことで，予測精度を向上させることができるかを検証した．紙の熱伝導率と，紙の密度（空隙率）とは相関すると推定され，紙の密度は，坪量と紙厚により算出できる．入力に紙厚を追加した排紙部紙温度予測モデルにおける学習結果を Fig. 2-8 に示す．予測温度は実測温度に対して ± 3 °C以内であった．Fig. 2-9 は，Exp. No. 17～20 の検証実験の予測精度である．MSE と R^2 が若干改善されたものの，予測誤差は ± 9 °Cであり，前節と同様，不十分な予測精度であった．

Fig. 2-10 は，検証実験における排紙部紙温度プロファイルである．Exp. No. 17 は ± 9 °Cの誤差であり，Exp. No. 18 は ± 7 °Cの誤差であった．Fig. 2-9 でも Exp. No. 17 が最も誤差が大きく，次に Exp. No. 18 が大きいことが確認され，Exp. No. 19, 20 の予測誤差は改善された．Exp. No. 19, 20 は平滑度の高いコート紙であり，機械学習モデルが平滑性の高いコート紙に対して誤差を小さくするように調整され，一方で平滑性の低い普通紙に対してはその分低い温度を予測し，誤差が大きくなった．紙温度に影響する紙の特性値の入力として坪量と厚さ以外の平滑度によって予測精度が改善することを次節で検証する．

Table 2-6 入力に紙厚を追加した排紙部紙温度予測モデルの入出力

Input	Output
Heat roller temperature Fusing roller temperature Fusing roller sensor temperature Pressure roller temperature Printing speed Paper basis weight Paper thickness	Outlet paper temperature




Fig. 2-8 入力に紙厚を追加した排紙部紙温度予測モデルの学習実験の予測精度




Fig. 2-9 入力に紙厚を追加した排紙部紙温度予測モデルの検証実験の予測精度




Fig. 2-10 入力に紙厚を追加した排紙部紙温度予測モデルの検証実験における紙温度プロファイル

2.2.5.3 入力に紙厚，平滑度を追加した排紙部紙温度予測モデル

前節では紙温度に影響する紙の特性値の入力として坪量と厚さを追加しても十分ではなかったことが予測精度の悪化要因と考えられ，坪量，紙厚に加え，平滑度を入力として加えたことで，予測精度を向上させることができるかを検証した．入力と出力を Table 2-7 に示す．紙と定着ベルト，加圧ローラとの接触熱抵抗と，紙の平滑度とは相関すると推定される．Fig. 2-11 は，入力に紙厚，平滑度を追加した排紙部紙温度予測モデルにおける学習実験の予測精度を示す．予測温度は実測温度に対して ± 3 °C以内であった．Fig. 2-12 は，Exp. No. 17～20 の検証実験の予測精度である．予測温度と実測温度の差は最大 ± 5 °Cとなり，目標値を達成し，MSE と R^2 についても改善された．Fig. 2-13 は，検証実験における排紙部紙温度プロファイルであり，いずれの紙に対しても予測精度が向上したことを確認した．坪量，紙厚に相関があると推定される熱容量，熱伝導率に加え，平滑度を追加することによって，紙と定着ベルト，加圧ローラとの接触熱抵抗の影響についても予測できることが示唆された．

Table 2-7 入力に紙厚，平滑度を追加した排紙部紙温度予測モデルの入出力

Input	Output
Heat roller temperature	Outlet paper temperature
Fusing roller temperature	
Fusing roller sensor temperature	
Pressure roller temperature	
Printing speed	
Paper basis weight	
Paper thickness	
Paper smoothness	




Fig. 2-11 入力に紙厚，平滑度を追加した排紙部紙温度予測モデルの学習実験の予測精度




Fig. 2-12 入力に紙厚，平滑度を追加した排紙部紙温度予測モデルの検証実験の予測精度




Fig. 2-13 入力に紙厚，平滑度を追加した排紙部紙温度予測モデルの検証実験における紙温度プロフィール

2.2.5.4 過学習の検証

過学習とは，機械学習モデルが学習実験の条件に対しては適応しているが，学習実験以外の条件に対しては適応できていない状態を指す．機械学習では，学習実験条件には含まれない条件においても適応できている汎化性能が必要となる．過学習が発生する原因として，ニューロン数が多く，表現力の高いモデルであり，学習実験データが少ないことが挙げられる[2-14]．

Fig. 2-5, Fig. 2-8, Fig. 2-11 は，学習実験における予測精度であり，予測精度は実測温度に対して，ほぼ ± 3 °C以内であった．一方，Fig. 2-6, Fig. 2-9 は，検証実験の予測精度であり，予測温度と実測温度の差が最大 ± 9 °Cであった．学習実験よりも検証実験の誤差が大きく，過学習が発生したと判断される．学習実験の予測精度は，目標の ± 5 °Cを達成しているため，必要な表現力は得られているが，学習データが不足していたため，過学習が発生した．Fig. 2-12 では入力に紙の平滑度を追加することで，過学習が抑制され，汎化性能が向上した．

2.2.6 特許出願

機械学習による排紙部温度予測を基にした発明について特許出願を行った[6-2]。特許内容の概要は、以下のとおりである。発明に関する図面を Fig. 2-14, Fig. 2-15 に示す。

【課題】 記録材の定着後温度を検知する温度センサを設けることなく、温度影響部材の温度調整を適切に行う。

【解決手段】 画像が形成された記録材に該画像を加熱定着させる加熱定着手段と、前記加熱定着手段による定着後の記録材の温度に影響を与える温度影響部材（加圧ローラ、冷却ローラ）と、前記温度影響部材の温度を調整する調整手段 110、120 とを有する画像形成装置であって、前記調整手段 110、120 は、前記記録材の物性情報と、前記加熱定着手段の温度情報（温度センサ 25h、25i、25j の検知情報）と、前記加熱定着手段を通過する記録材の搬送速度とに基づいて、該記録材の定着後温度が所定温度以下になるように前記温度影響部材の温度を調整する。

ところが、従来の画像形成装置においては、冷却直後の用紙の表側と裏側の温度を検知する温度センサを配置する必要がある、部品点数の削減、省スペース化に課題がある。

本発明によれば、記録材の定着後温度を検知する温度センサを設けることなく、温度影響部材の温度調整を適切に行うことができ、部品点数の削減、省スペース化、冷却装置の低騒音化、省エネルギー化を図ることができる。

【特許請求の範囲】

【請求項 1】

画像が形成された記録材に該画像を加熱定着させる加熱定着手段と、
前記加熱定着手段による定着後の記録材の温度に影響を与える温度影響部材と、
前記温度影響部材の温度を調整する調整手段とを有する画像形成装置であって、
前記調整手段は、前記記録材の物性情報と、前記加熱定着手段の温度情報と、前記加熱定着手段を通過する記録材の搬送速度とに基づいて、該記録材の定着後温度が所定温度以下になるように前記温度影響部材の温度を調整することを特徴とする画像形成装置。

【請求項 2】

請求項 1 に記載の画像形成装置において、
前記物性情報は、前記記録材の坪量、厚み、材質、平滑性のうちの少なくとも 1 つの情報を含むことを特徴とする画像形成装置。

【請求項 3】

請求項 1 又は 2 に記載の画像形成装置において、
前記加熱定着手段は、記録材の未定着画像付着面側に配置される加熱定着部材と、該記録材を該加熱定着部材へ加圧する加圧部材と、前記加熱定着部材を加熱する加熱手段とから構成されており、
前記温度情報は、前記加熱定着部材の温度、前記加圧部材の温度、前記加熱手段の温度のうちの少な

くとも1つの情報を含むことを特徴とする画像形成装置。

【請求項4】

請求項1乃至3のいずれか1項に記載の画像形成装置において、

前記調整手段は、前記物性情報と前記温度情報と前記搬送速度とに基づいて前記記録材の定着後温度を推定し、推定した定着後温度が所定温度以下になるように前記温度影響部材の温度を調整することを特徴とする画像形成装置。

【請求項5】

請求項4に記載の画像形成装置において、

前記調整手段は、前記記録材の物性情報と、前記加熱定着手段の温度情報と、前記加熱定着手段を通過する記録材の搬送速度とを含む複数の学習用データを用いて学習した推定プログラムを用いて、前記推定を行うことを特徴とする画像形成装置。

【請求項6】

請求項1乃至5のいずれか1項に記載の画像形成装置において、

前記加熱定着手段は、記録材の未定着画像付着面側に配置される加熱定着部材と、該記録材を該加熱定着部材へ加圧する加圧部材と、前記加熱定着部材を加熱する加熱手段とから構成されており、前記温度影響部材は、前記加圧部材を含むことを特徴とする画像形成装置。

【請求項7】

請求項6に記載の画像形成装置において、

前記調整手段は、前記加圧部材を冷却するための加圧部材冷却手段を制御して該加圧部材の温度を調整することを特徴とする画像形成装置。

【請求項8】

請求項1乃至7のいずれか1項に記載の画像形成装置において、

前記加熱定着手段による定着後の記録材を冷却する冷却部材を有し、
前記温度影響部材は、前記冷却部材を含むことを特徴とする画像形成装置。

【請求項9】

請求項6又は7に記載の画像形成装置において、

前記加熱定着手段による定着後の記録材を冷却する冷却部材を有し、
前記温度影響部材は、前記加圧部材のほかに前記冷却部材も含み、
前記物性情報は、前記記録材の厚みの情報を含み、
前記調整手段は、前記記録材の定着後温度が前記所定温度を超える場合、前記記録材の厚みが所定厚み未満であるときは、前記加圧部材の温度は調整せずに前記冷却部材の温度を調整し、前記記録材の厚みが所定厚み以上であるときは、前記加圧部材の温度及び前記冷却部材の温度の両方を調整することを特徴とする画像形成装置。

請求項10以降は省略する。




Fig. 2-14 実施形態における加圧ローラ，冷却ローラの温度調整における制御ブロック図




Fig. 2-15 実施形態における加圧ローラ，冷却ローラの温度調整の流れを示すフローチャート

2.3 LSTM による排紙部紙温度予測

前節では FNN と呼ばれる一般的なニューラルネットワークを用いたが、本節では、紙温度の予測に LSTM (Long short-term memory) と呼ばれるニューラルネットワークを使用する。LSTM の概要を記述する。

LSTM とは時系列データ、すなわち多数の時刻において記録された数値の系列を対象とした予測を行うことに優れた RNN (Recurrent neural network) の一種である[2-12]。一般的な RNN は、時系列に並んだデータを順番に入力しながらその情報の一部をモデル内に記憶しており、新しく入力されたデータと記憶している過去の情報をもとにその先の予測を行う。RNN は長期的特徴を学習することが難しいが、LSTM は長期的特徴も、短期的特徴も学習できるニューラルネットワークである[2-13]。

前節までの FNN による紙温度予測モデルにおいては、排紙部の紙温度を予測する際には、同時刻の温度情報を入力する必要があるが、未来の紙温度を予測することはできなかった。それに対して、本節で提案する LSTM による紙温度予測モデルにおいては、印刷開始後から所定期間における紙温度の時系列データから、その後に印刷される紙温度を予測することが可能になると考えられる。また、学習する印刷枚数は、連続大量印刷枚数となる場合もあるため、長期的特徴を学習できる LSTM が適していると考えられる。

2.3.1 実験装置

本実験で用いる実験装置は、前節 FNN モデルで用いた装置と同一であるが、Fig. 2-16, Table 2-8 に示すとおり、ヒートパイプセンサ (4) を追加した。




Fig. 2-16 実験装置の概要図

Table 2-8 温度センサの測定対象、センサ種類

Sensor No.	Target	Sensor type
(1)	Heat roller	Radiation thermometer
(2)	Fusing roller	Radiation thermometer
(2)	Fusing roller sensor	Radiation thermometer
(3)	Pressure roller	Radiation thermometer
(4)	Heat pipe	Thermocouple
(5)	Outlet paper	Radiation thermometer

2.3.2 紙種と紙物性

使用した紙種は Table 2-9 に示すとおりであり，FNN モデルで用いた紙種とは異なる．

Table 2-9 実験に用いた紙種と紙物性

Paper type	Basis weight [g/m ²]	Thickness [μm]	Smoothness [s]	Density [kg/m ³]	Surface coating
A	53.2	66.0	82	806	Non-coated
B	81.0	94.3	95	859	Non-coated
C	156.0	184.3	40	848	Non-coated
D	100.0	101.5	788	980	Coated
E	160.6	171	731	940	Coated
F	68.2	91.1	47	748	Non-coated
G	127.6	149.1	50	854	Non-coated
H	133.0	138.5	777	960	Coated
I	127.4	145	102	880	Coated
J	103.4	118.1	79	877	Non-coated
K	104.2	121.1	66	861	Non-coated

2.3.3 排紙部紙温度予測に用いた LSTM モデル

以降では，時系列データの時刻による分割単位，すなわち時系列データ一時刻分を「タイムステップ」と称する．

排紙部紙温度の予測には Fig. 2-17 に示す多数のタイムステップでの入力に対し出力が単一のタイムステップである多対一構造の LSTM[2-14]を用いた．但し， I^t ， O^t はそれぞれタイムステップ t での説明変数と目的変数を示す．タイムステップ $t+1$ から $t+S$ までの複数の時刻での説明変数を元にタイムステップ $t+S+L$ での目的変数を予測するようなモデルとなっている． S は入力サイズ， L は予測対象タイムステップとの間隔である．本研究の排紙部紙温度予測モデルでは紙 1 枚の印刷を

1 タイムステップとし, $L = 1$, $S = 20$ とした. 説明変数と目的変数はデータセットの中から選択し Table 2-10 のとおりに設定した.




Fig. 2-17 多対一構造の LSTM

Table 2-10 紙温度予測モデルの入力と出力

Category	Input	Output
Components temperature	Pressure roller temperature Fusing roller temperature Fusing roller sensor temperature Heat pipe temperature	Pressure roller temperature Fusing roller temperature Fusing roller sensor temperature Heat pipe temperature
Paper properties	Basis weight Thickness Smoothness	
Printing settings	Fusing temperature Printing speed Single/Double sided Amount of toner Paper size	
Paper temperature	Outlet paper temperature	Outlet paper temperature

2.3.4 実験条件

実験条件は, Table 2-11 に示す 49 条件である. 片面印刷, 両面印刷の条件で分けられ. 両面印刷の場合は片面を印刷した後, 反転してもう一方の面が定着ニップを通過するため, 紙温度は高くなる. 定着温度は標準温度(Std.), ± 20 °C, ± 10 °C, $+13$ °C, $+5$ °C, 印刷速度は 350, 290, 180 mm/s の中から選択した. 画像は全面均一画像とし, 白紙の場合を 0%, 単色の場合を 100%, 2 色の場合を 200% とした. 紙サイズは A3 と A4 とした. A4 サイズは搬送方向長さが短辺 (210 mm) となるように横向

きで印刷した。

これらの測定データをモデルの学習に用いるデータセットと、検証に用いるデータセットに Table 2-12 のように分割した。Exp. No. は、Table 2-11 に記載した Exp. No. に対応している。紙温度測定を全 49 件の条件で実施し、この測定を元にデータセットを作成し、その内 36 件を用いて機械学習モデルの学習を行い、残りの 13 件で機械学習モデルの検証を実施した。

また、評価の結果は既存の研究との比較として、FNN 予測モデルを作成した。この予測モデルの入力は、Table 2-10 に示した LSTM モデルの入力特徴量から排紙部紙温度 (Outlet paper temperature) を除いたものを使用している。また、FNN モデルによる予測では LSTM モデルとは異なり部品温度は予測値ではなく全て実測値を用いている。FNN モデルでは未来の値の予測は行えず、部品温度から同時刻の紙温度を予測しているためである。

Table 2-11 実験条件

Exp. No.	Single/ Double sided	Paper type	Printing speed [mm/s]	Fusing temperature [°C]	Amount of toner	Paper size
1	Single	A	350	-20	0	A3
2		A	350	Std.	0	
3		A	350	+20	0	
4		A	290	Std.	0	
5		A	290	+20	0	
6		B	350	-20	0	
7		B	350	Std.	0	
8		B	350	+20	0	
9		B	290	-20	0	
10		B	290	+20	0	
11		B	180	-20	0	
12		B	180	+20	0	
13		C	350	-20	0	
14		C	350	Std.	0	
15		D	290	-20	0	
16		D	290	+20	0	
17		E	180	-20	0	
18		E	180	+20	0	
19		F	350	+10	0	
20		G	350	-15	0	

21		H	180	+15	0	
22		I	290	-10	0	
23		J	290	+5	0	
24	Double	A	350	Std.	0	
25		B	350	-20	0	
26		B	350	+20	0	
27		B	290	Std.	0	
28		B	290	+20	0	
29		C	290	-20	0	
30		C	290	Std.	0	
31		C	290	+20	0	
32		E	290	+20	0	
33		K	350	+20	0	
34	Single	C	180	+13	200%	A4
35		D	290	+13	200%	
36		G	180	+13	100%	
37		H	180	+13	100%	
38		K	290	+13	0	
39		K	290	+13	100%	
40	Double	C	180	+13	200%	
41		D	290	+13	0	
42		D	290	+13	100%	
43		E	180	+13	0	
44		E	180	+13	100%	
45		E	180	+13	200%	
46		G	180	+13	100%	
47		H	180	+13	200%	
48		K	290	+13	0	
49		K	290	+13	200%	

Table 2-12 学習用データセット及び検証用データセットへの分割

	Train dataset	Test dataset
Exp.	1, 3-18, 24, 25, 27-29, 31, 32,	2, 19-23, 26, 30, 33, 34,
No.	35, 36, 38-44, 46, 48, 49	37, 45, 47

2.3.5 排紙部紙温度の学習，予測手順

分割されたデータセットのうちテスト用のデータセットを用いて前節で作成したモデルの評価を行った．テスト用のデータセットの条件で紙温度の予測を行い，予測値と測定値の比較を行った．


紙温度の予測は以下の手順で行った．

1. 印刷が開始されて紙が最初に排紙されてからモデルの入力タイムステップ数である S 枚排紙されるまでの部品温度データとその他の特徴量を入力として， $S+1$ 枚目に排紙される紙の温度とその時点での部品温度の予測を行う．
2. 1. で予測された $S+1$ 枚目が印刷された時点での部品温度及び紙温度を入力として扱い，2 枚目から $S+1$ 枚目の部品温度データ，紙温度データ（うち $S+1$ 枚目のみ予測値）とその他の特徴量を入力として， $S+2$ 枚目に排紙される紙の温度とその時点での部品温度の予測を行う．
3. 部品温度の予測値を次に行う予測の入力とすることにより紙温度を順番に予測していく．予測対象である条件で印刷された紙の温度が全て予測されるまでこの操作を繰り返す．


2.3.6 結果と考察

LSTMモデルについて，全13件の検証データ全てを併せて予測値と測定値を比較した散布図をFig. 2-18 (a)に示す．横軸が実測値，縦軸が予測値となっており，中央の傾き1の直線との距離が近いほど測定値と予測値が一致していることを示す．紙温度の誤差はほぼ ± 4 ℃以内に収まっており，誤差の最大値は4.08℃，MSEは2.3であった．検証データにはトナーを使用した条件も含まれている．トナーを使用した際の紙温度は使用しなかった際の紙温度と大きく差異があるが，白紙印刷とトナーを用いた印刷どちらも4.1℃以内という高い精度で予測できている．また，散布図に記入されている全測定点のうち77%が2℃以下の誤差となっており，誤差3℃以下のものは全体の94%であった．3℃以上など誤差が大きいものは全体の少数であり，これは主に印刷開始から100枚程度などの過渡的に紙温度が変化する部分に由来しており，印刷中盤以降の紙温度が安定した部分での誤差は更に小さい．また，比較として，FNNにより作成した予測モデルでの予測値と測定値の散布図をFig. 2-18 (b)に示す．FNNモデルの誤差の最大値は6.6℃，MSEは2.8であった．入力特徴量の部品温度について，FNNモデルでは全て測定値を入力に用いているのに対し，LSTMモデルでは各条件につき印刷開始からの20枚の測定値を用い，以降の部品温度は推定値を利用しているにも関わらず，LSTMはFNNよりも小さい誤差で紙温度の予測が可能であることが示された．時系列データを入力することにより，予測精度が向上すると考えられる．また，LSTMモデル，FNNモデルのどちらにおいても，検証実験における全13条件のうち，No. 45の予測誤差が大きくなった．No. 45は両面印刷，コート

紙，トナー量 200%であり，これらの条件に対してトナー有りの条件での学習が不十分であったことが要因と考えられ，過学習を発生させたことになる．



(a) LSTM モデルによる予測



(b) FNN モデルによる予測

Fig. 2-18 LSTM による排紙部紙温度の予測精度，FNN との比較

2.4 機械学習による紙物性予測

前節で示したように，排紙部の紙温度を高精度に予測するために，機械学習モデルを適用することが有効であることが示された．しかし，印刷条件や紙の種類は多岐にわたり，市場で使用される紙種は数 100 種類以上になる機種もある．排紙部の紙温度を高精度に予測するためには，前節で示したように紙物性として坪量，厚さ，平滑度が必要となる．市場での使用される全ての紙銘柄の特性値を取得することは容易ではない．紙の特性値を検知し判定できる測定する装置も開発されているが[2-15][2-16]，ある程度の実験データがあれば，機械学習を用いて予測することも可能と考えられる．そこで，本章では，印刷時における定着装置内のセンサ温度応答から紙物性を予測することを検討した．

2.4.1 実験装置

本実験で用いる実験装置はFig. 2-19に示すとおりであり，前節LSTMモデルで用いたFig. 2-16に示す装置と同一であり，温度センサも同一のものを使用した．




Fig. 2-19 実験装置の概要図

Table 2-13 温度センサの測定対象，センサ種類

Sensor No.	Target	Sensor type
(1)	Heat roller	Radiation thermometer
(2)	Fusing roller	Radiation thermometer
(2)	Fusing roller sensor	Radiation thermometer
(3)	Pressure roller	Radiation thermometer
(4)	Heat pipe	Thermocouple
(5)	Outlet paper	Radiation thermometer

2.4.2 紙種と紙物性

使用した紙種は Table 2-14 に示すとおりであり，FNN モデル，LSTM モデルで用いた紙種とは異なる．

Table 2-14 実験に用いた紙種と紙物性

Paper type	Basis weight [g/m ²]	Thickness [μm]	Smoothness [s]
A	53	66	82
B	81	94	95
C	156	184	40
D	100	102	788
E	161	171	731
F	80	91	124
G	104	121	66
H	128	149	50
I	68	91	47
J	133	139	777
K	127	145	102
L	103	118	79

2.4.3 機械学習アルゴリズム

Fig. 2-19 に示す実験装置で測定された温度を用いて，紙物性を予測するための ANN を用いた機械学習アルゴリズムを開発した．入力には，これまで各時刻における定着装置内の部材の温度としたが，ここでは 250 枚連続印刷の部材の温度プロファイルとする．また，紙物性を予測することが目的であるため，出力は紙物性の坪量，厚さ，平滑度とした．紙物性予測モデルの入力と出力を Table 2-15 に示す．本章の ANN の基本構成は，前節の FNN モデル Fig. 2-2 と同一であるが，入力が連続 250 枚印刷，出力が坪量，厚さ，平滑度の 3 種類になることから，隠れ層のニューロン数は，2000，1000，500 に増加させた．

Table 2-15 紙物性予測モデルの入出力

Input	Output
Heat roller temperature profile	Basis weight
Fusing roller temperature profile	Thickness
Fusing roller sensor temperature profile	Smoothness
Pressure roller temperature profile	
Heat pipe temperature profile	
Printing speed	

2.4.4 実験条件

実験条件は Table 2-16 に示す 30 条件であり, Exp. No. 1~24 が学習実験, Exp. No. 25~30 が検証実験である.

Table 2-16 実験条件

Exp. No.	Paper type	Fusing temperature [°C]	Printing speed	Purpose
1	A	-20	Std.	Training
2		Std.	Std.	
3		+20	Std.	
4	B	-20	Std.	
5		Std.	Std.	
6		+20	Std.	
7		-20	-17%	
8		+20	-17%	
9		-20	-49%	
10		+20	-49%	
11	C	-20	Std.	
12		Std.	Std.	
13	D	-20	-17%	
14		+20	-17%	
15	E	-20	-49%	
16		+20	-49%	
17	F	-20	Std.	


18		+20	Std.	
19	G	-20	Std.	
20		+20	Std.	
21		-20	-17%	
22		+20	-17%	
23		-20	-49%	
24	H	+20	-49%	Validation
25	I	+10	Std.	
26	H	-15	Std.	
27	J	+15	-49%	
28	K	-10	-17%	
29		-10	-49%	
30	L	+5	-17%	

2.4.5 結果と考察


Fig. 2-20 に紙物性予測モデルの学習実験の予測精度を示す．学習実験においては，坪量，厚さ，平滑度のいずれも高い精度で予測できていた．

Fig. 2-21 には紙物性予測モデルの検証実験の予測精度を示す．坪量，厚さの予測精度は， $\pm 10\%$ 以内であったが，平滑度の予測精度は 10% 以内には収まらず，過学習と判断された．平滑性に影響する温度検知のサンプリングやデータの前処理方法を改善することで，過学習を抑制する余地があると考えられる．


紙の特性を予測する場合，入力 は定着装置の 250 枚連続印刷で取得した温度データあり，出力は，坪量，厚み，平滑度の紙特性である．定着装置では，加熱ローラ，定着ローラはほぼ一定温度に制御されるが，加圧ローラやヒートパイプには熱源がない．そのため，加圧ローラやヒートパイプの温度は紙の熱物性に依存する．坪量，坪量と厚みとから算出される密度，平滑度はそれぞれ熱容量，熱伝導率，接触熱抵抗と相関があると推定される．温度データから機械学習モデルがこれらの特徴を予測していると考えられる．



(a) 坪量




(b) 厚さ




(c) 平滑度


Fig. 2-20 紙物性予測モデルの学習実験の予測精度



(a) 坪量



(b) 厚さ



(c) 平滑度

Fig. 2-21 紙物性予測モデルの検証実験の予測精度

ここで、定着装置の加熱ローラ、定着ローラ、加圧ローラ、ヒートパイプの温度から紙物性を予測できる理由について考察する。Fig. 2-22 は、加熱ローラ、定着ローラ、加圧ローラ、ヒートパイプの温度プロファイルを表している。(a)はExp. No. 1, Paper Aであり、坪量は 53 g/m^2 である。(b)はExp. No. 19, Paper Gであり、坪量は 104 g/m^2 である。平滑度はどちらもほぼ等しい。加圧ローラ温度とヒートパイプ温度は、(a)の坪量の小さい紙では高く、(b)の坪量の大きい紙では低くなった。坪量が多い場合は、紙の熱容量も大きく、加圧ローラからの伝熱も大きいため、坪量が小さい場合に比べて熱源を持たない加圧ローラ温度は低くなったと考えられる。また、坪量の大きい紙の温度は低いため、ヒートパイプの温度も坪量の小さい紙に比べて低くなった。

次に、加熱ローラ、定着ローラ、加圧ローラ、ヒートパイプの温度から紙の平滑度が予測できる理由について考察する。Fig. 2-22(c)は、Exp. No. 13, Paper Dであり、平滑度が 788 s である。(d)は、Exp. No. 21, Paper Gであり、平滑度が 66 s である。坪量はどちらもほぼ等しい。加圧ローラ

温度はどちらもほぼ等しいが、ヒートパイプ温度は、(a)の平滑度の高い紙では高く、(b)の平滑度の低い紙では低くなった。平滑度が高い場合は、定着ベルトとの接触熱抵抗が低くなり、紙温度が高くなり、ヒートパイプ温度も高くなったと考えられる。また、加圧ローラとの接触熱抵抗も低くなるが、紙温度が高くなるため加圧ローラ温度は(d)の平滑度が低い紙と比べて低くならなかった。




Fig. 2-22 連続印刷時の加熱ローラ、定着ローラ、加圧ローラ、ヒートパイプの温度プロフィール

2.4.6 特許出願

機械学習による排紙部温度予測を基にした発明について特許出願を行った[6-6]。特許内容の概要は、以下のとおりである。発明に関する図面を Fig. 2-23, Fig. 2-24 に示す。

【特許請求の範囲】

【請求項 1】

画像が形成された記録シートに該画像を加熱定着させる定着手段と、

前記定着手段の温度を制御する定着温度制御手段とを有する画像形成装置であって、
前記定着手段による定着後の記録シートを冷却する冷却手段と、
前記記録シートが前記定着手段を通過するときの該定着手段の温度を検知する定着温度検知手段と、
前記記録シートが前記冷却手段を通過するときの該冷却手段の温度を検知する冷却温度検知手段とを有し、
前記定着温度制御手段は、前記定着温度検知手段及び前記冷却温度検知手段の検知結果に基づいて、前記定着手段の温度を制御することを特徴とする画像形成装置。

【請求項 2】

請求項 1 に記載の画像形成装置において、
前記冷却手段の温度を調整する冷却温度制御手段を有し、
前記冷却温度制御手段は、前記定着温度検知手段及び前記冷却温度検知手段の検知結果に基づいて、前記冷却手段の温度を制御することを特徴とする画像形成装置。

【請求項 3】

画像が形成された記録シートに該画像を加熱定着させる定着手段と、
前記定着手段による定着後の記録シートを冷却する冷却手段と、
前記冷却手段の温度を調整する冷却温度制御手段とを有する画像形成装置であって、
前記記録シートが前記定着手段を通過するときの該定着手段の温度を検知する定着温度検知手段と、
前記記録シートが前記冷却手段を通過するときの該冷却手段の温度を検知する冷却温度検知手段とを有し、
前記冷却温度制御手段は、前記定着温度検知手段及び前記冷却温度検知手段の検知結果に基づいて、前記冷却手段の温度を制御することを特徴とする画像形成装置。

【請求項 4】

請求項 2 又は 3 に記載の画像形成装置において、
前記冷却手段は、通過する記録シートから吸熱する吸熱部材と、該吸熱部材を空冷又は液冷する冷却部材とを含み、
前記冷却温度制御手段は、前記冷却部材の冷却能力を制御して前記冷却手段の温度を制御することを特徴とする画像形成装置。

【請求項 5】

請求項 4 に記載の画像形成装置において、
前記吸熱部材は、ヒートパイプであることを特徴とする画像形成装置。

【請求項 6】

請求項 4 に記載の画像形成装置において、
前記吸熱部材は、通過する記録シートをガイドするガイド部材であることを特徴とする画像形成装置。

【請求項 7】

画像が形成された記録シートに該画像を加熱定着させる定着手段と、前記定着手段による定着後の記録シートを冷却する冷却手段とを備える画像形成装置によって画像が記録される記録シートの物性情報を推定する推定装置であって、

記録シートが前記定着手段を通過するときの該定着手段の温度情報と、該記録シートが前記冷却手段を通過するときの該冷却手段の温度情報とに基づいて、該記録シートの物性情報の推定を行うことを特徴とする推定装置。

【請求項 8】

請求項 7 に記載の推定装置において、

前記物性情報は、記録シートの坪量、厚さ及び平滑度のうちの少なくとも 1 つであることを特徴とする推定装置。

【請求項 9】

請求項 7 又は 8 に記載の推定装置において、

記録シートの光学特性を検知する光学センサの検知結果にも基づいて、該記録シートの物性情報の推定を行うことを特徴とする推定装置。

【請求項 10】

請求項 7 乃至 9 のいずれか 1 項に記載の推定装置において、

物性情報が既知である学習対象記録シートが学習対象画像形成装置の定着手段を通過するときの該定着手段の温度情報と、該学習対象記録シートが該学習対象画像形成装置の冷却手段を通過するときの該冷却手段の温度情報とを含む複数の学習用データを用いて学習した推定プログラムを用いて、前記推定を行うことを特徴とする推定装置。




Fig. 2-23 実施形態における定着装置及び冷却装置の温度制御に関する制御ブロック図




Fig. 2-24 実施形態における定着装置及び冷却装置の温度制御の流れを示すフローチャート

2.5 結言

本章では、電子写真方式を用いた商用印刷機における排紙部紙温度予測、紙物性予測に、機械学習アルゴリズムを用いた。その結果、複雑な物理モデルを用いることなく、機械学習モデルのみによって高精度に予測できることが示された。

第一の機械学習モデルとして FNN モデルを用い、入力として印刷条件の他に紙物性値として坪量、厚さ、平滑度を入力することで、 $\pm 5^{\circ}\text{C}$ の排紙部紙温度の予測精度が得られた。紙特性のうち、坪量のみ入力した場合の予測精度は、 $\pm 9^{\circ}\text{C}$ であり、過学習と判定されたが、坪量、厚さ、平滑度を入力することで、過学習を抑制し、予測精度は $\pm 5^{\circ}\text{C}$ に向上し、目標値以内となった。

第二の機械学習モデルとして LSTM モデルを用い、連続印刷における時系列データを入力とし、印刷開始から 20 枚のデータに基づき、数 100 枚後の温度を予測することが可能となった。FNN では未来の紙温度を予測することができないが、LSTM モデルでは印刷開始後所定期間の温度データからその先に印刷される紙の温度を FNN モデルよりも高精度に予測が可能であった。また、LSTM モデル

の予測精度と比較するための同じ条件における FNN モデルの予測精度は ± 6 °Cであったが、入力を時系列データとすることにより LSTM モデルでは ± 4 °Cとなった。

第三の機械学習モデルとして紙物性を予測できる機械学習モデルを構築した。印刷時における定着装置内の定着装置内の部材温度、ヒートパイプ温度プロファイルを学習することで、坪量、厚さは $\pm 10\%$ 以内の予測精度が得られたが、平滑度の予測精度は 10%以内には収まらず、過学習と判断された。平滑性に影響する温度検知のサンプリングやデータの前処理方法を改善することで、過学習を抑制する余地があると考えられる。

2.6 参考文献

- [2-1] T. Takenaka, T. Asami, M. Iio, T. Sugiyama, A. Yamazaki, S. Akatsu, M. Nakayama, B. Shu, “New Technologies for Printed Material’s Advanced Value in the Production Printing Market,” *Proc. NIP27*, pp. 537-539(3), 2011.
- [2-2] S. Aoki, H. Iimura, Y. Ogino, K. Nakamura, I. Maeda, N. Sugimoto, S. Tanaka, “New Effect of AC High Field on Toner Transfer,” *Proc. NIP29*, pp. 545-549(5), 2013.
- [2-3] S. Kawasaki, K. Yamazaki, K. Hemmi, S. Kuramoto, K. Kato, K. Fushinobu, “Prediction and control technique of the paper media temperature after fusing in electrophotographic process,” *Proc. ASME InterPACK 2019*, IPACK2019-6396, 2019.
- [2-4] E. Dursunkaya, S. Kawasaki, K. Hemmi, K. Yamazaki, S. Kuramoto, K. Kato, K. Fushinobu, “Investigation of The Effect of Paper Types on The Paper Temperature in The Electrophotographic Process by Using Machine Learning,” *Proc. ISTP30*, ISTP012, 2019.
- [2-5] 日本工業規格, JIS P8124 (紙及び板紙-坪量の測定方法), 2011.
- [2-6] 日本工業規格, JIS P8118 (紙及び板紙-厚さ, 密度及び比容積の試験方法), 2014.
- [2-7] 日本工業規格, JIS P8155 (紙及び板紙-平滑度試験方法-王研法), 2010.
- [2-8] M. Abadi, et al., “TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems,” <http://tensorflow.org/>, 2015.
- [2-9] F. Chollet, et al., “Keras,” <https://keras.io>, 2015.
- [2-10] F. Pedregosa, et al., “Scikit-learn: Machine Learning in Python,” *Journal of Machine Learning Research*, Vol. 12, pp. 2825-2830, 2011.
- [2-11] D. P. Kingma, J. L. Ba, “Adam: A Method for Stochastic Optimization,” *Proc. ICLR 2015*, 2015.
- [2-12] 手塚 太郎, “仕組みが分かる深層学習,” 朝倉書店, 2018.
- [2-13] 巢籠 悠輔, “詳解ディープラーニング-TensorFlow・Keras による時系列データ処理,” マイナビ出版, 2017.
- [2-14] 斎藤 康毅, “ゼロから作る Deep Learning -Python で学ぶディープラーニングの理論と実装,” オライリー・ジャパン, 2016.
- [2-15] 吉村 和利, “インテリジェントメディアセンサーの開発,” KONICA MINOLTA TECHNOLOGY REPORT, Vol. 17, 2020.
- [2-16] 星 文和, 大場 義浩, 後藤 一磨, 三坂 好央, 佐藤 慎司, “拡散反射光の偏向特性による用紙銘柄判別,” Ricoh Technical Report, No. 41, 2016.

第3章 機械学習と熱回路網法による紙温度予測

3.1 緒言

第2章では、ブロッキング課題に対して、排紙部紙温度を機械学習のFNNモデル、LSTMモデルを構築し、従来の複雑な物理モデルを必要とせず、入力と出力に適切な特徴量を選定することで、高精度な予測結果を得られることが明らかになった。また、定着装置内の部材温度、ヒートパイプ温度プロファイルを学習することで、紙物性予測についても機械学習により可能であることが確認された。

一方、高精度な機械学習モデルを構築するためには多くの学習実験が必要であった。FNNモデルにおいては、紙5種、定着温度3パターン、印刷速度3パターンを組み合わせ、合計16パターンの学習実験を行った。LSTMモデルにおいては、紙8種、定着温度4パターン、印刷速度3パターン、トナー量3パターンを組み合わせ、合計36パターンの学習実験を行った。紙物性予測においては、250枚の連続印刷が必要であった。

また、学習していない条件については予測することが困難であった。例えば、FNNモデルにおいては入力に紙の特性値として、坪量、厚さ、平滑度を選定したが、入力に平滑度を選定しなかった場合には、予測精度が不十分であった。また、平滑度を変えた条件で学習していなければ、検証実験で普通紙とコート紙の温度差は予測できていなかったと考えられる。

一方、従来の熱物理モデルは、実機が無い場合や学習していない条件でも予測可能であり、定着プロセスにおける紙とトナーへの伝熱現象の解析は多く行われてきた。AL-Rubaieyらは、定着ニップにおいて、紙の特性が定着部材の温度変化やトナー定着性、画像品質に与える影響を調査した[3-1]。Sandersらは、定着定着に影響を与える紙の化学的・物理的特性を特徴付け、紙の表面エネルギーと定着品質との間に相関関係を示した[3-2]。大原らは、定着時の紙の厚さ方向の水分移動を測定し、ペーパーカールのメカニズムを解析した[3-3]。Bandyopadhyayらは、定着ニップ部において紙内部の温度、圧力、水分を解析するためのシミュレーション技術を提案した[3-4]。Simulaらは、定着部材から紙への伝熱に及ぼす紙の熱拡散率と熱容量の影響を調査した[3-5]。

また、定着プロセスや、定着プロセス後の機内への影響をモデル化する際に、紙の熱物性値を考慮する必要がある。紙の熱伝導率、比熱といった熱物性値や、定着ニップ部と紙との接触熱抵抗は、定着プロセスのモデル化や紙種ごとの温度応答の予測に重要であるが、紙は繊維、表面コーティング、填料、水分などで複雑に構成されており、温度応答を正確に予測するための熱物性測定が困難である。

Lavrykovらは、様々な紙の熱物性を測定し、紙の密度と灰分が熱物性に及ぼす影響を調査した[3-6]。Hiroseらは、紙の熱物性を測定し、様々な紙の温度応答を測定した[3-7]。

このように、定着部の解析モデルが開発され、また紙の熱物性も測定されてきたが、紙の種類が多いため紙の熱物性値を正確に測定することが難しく、また、定着工程での加熱時間は、熱流計法や示差走査熱量計（DSC）法などの測定時間スケールと大きく異なるため、それらの測定方法で測定した熱物性を熱物性モデルに入力しても、実際の温度応答と異なる結果となる場合がある。また、定着プロセスのメカニズムは一般的に複雑であり、定着ニップ部での熱的相互作用を表す熱物理モデルを開発することは困難であった。

これらを背景に、本章では、従来から用いられてきた定着プロセスの1次元熱回路網モデルに基づき、紙の熱物性を予測できる機械学習モデルを用いて、少ない学習実験で定着プロセス後の紙温度を高精度に予測できる手法を開発することを目的とする。また、従来の物理モデルとの予測精度比較を行うことで、本研究で提案する手法の有効性を明らかにする。

3.2 実験装置

実験は、定着温度 (Fusing temperature) と印刷速度 (Printing speed) を任意の値に制御可能であり、ヒータへの通電量制御装置と、回転駆動制御装置を含む定着装置の単体試験機を用いて行った。概略図を Fig. 3-1 に示す。第2章の実験で用いた定着装置とは一部異なる。印刷速度とは、紙搬送速度であり、定着ベルト、加圧ローラの周速度と等しい。定着装置には、定着ローラ温度センサ (Sensor 1)、加圧ローラ温度センサ (Sensor 2)、紙温度センサ (Sensor 3) が搭載されている。センサ3は、定着ニップ部の出口位置から紙搬送方向下流側に 50 mm の位置に配置されている。

なお、以下の項目で用いる定着温度 (Fusing temperature) とは、定着ベルトの目標温度であり、定着ローラ温度センサ (Sensor 1) が目標温度に追従するようにヒータへの通電を制御する。




Fig. 3-1 定着装置の単体試験機の概略図

3.3 紙種と紙物性

本章の目的は、異なる印刷条件、異なる紙種における紙温度の予測手法を開発することであるため、本実験では、Table 3-1 に示す坪量、厚さ、平滑度、表面コーティング、密度、灰分量の異なる Paper A, B, C, D の4種類の紙で実験を行った。第2章の実験で用いた紙とは一部異なる。これらの紙の特性は、定着ニップ内における定着部材から紙への伝熱、温度上昇、定着ニップ後における温度低下に影響を与える。坪量、厚さ、平滑度、表面コーティング、密度についての説明は第2章で記述したとおりである。灰分 (Ash content) とは、主に填料 (炭酸カルシウム、タルク、クレーなど) の量


であり、白色度、表面平滑性などを調整する目的で含まれている。Paper A, Paper Bは、表面コーティングが無い普通紙であり、坪量が異なる。Paper A, Paper Bは、表面コーティングを有するコート紙であり、坪量はPaper A, Paper Bとそれぞれほぼ同じである。

Fig. 3-2 に走査型電子顕微鏡（SEM）による紙の表面観察結果を示す。Paper A, Paper Bは、繊維が折り重なり、それらの間に填料が分布している。Paper C, Paper Dは、表面はコーティングされているため、表面に繊維は見られない。


Fig. 3-3 にレーザ顕微鏡による紙表面形状の観察結果を示す。Paper A, Paper Bは繊維の折り重なりにより最大 20 μm 程度の凹凸がある。Paper C, Paper Dの表面は平滑であり、凹凸は最大 10 μm 程度である。

Table 3-1 紙種と紙物性


Paper type	Basis weight [g/m ²]	Thickness [μm]	Smoothness [s]	Surface coating	Density [kg/m ³]	Ash content (wt%)
A	103	123	66	Non-coated	840	19.0%
B	154	184	40	Non-coated	840	19.3%
C	98	100	788	Coated	980	18.8%
D	161	171	731	Coated	940	14.2%




(a) Paper A



(b) Paper B



(c) Paper C



(d) Paper D

Fig. 3-2 走査型電子顕微鏡 (SEM) による紙の表面観察




Fig. 3-3 レーザ顕微鏡による紙の表面形状観察

3.4 実験条件

実験条件は、Table 3-2 に示す 16 パターンとした。紙は Paper A, B, C, D の 4 種類、印刷速度は 150, 200, 250, 300 mm/s の 4 パターン、定着温度は 130 °C から 170 °C まで 10 °C 刻みの 5 パターンとし、合計で 80 パターンとした。加圧ローラ内部には加熱源を有していないが、定着ローラ温度を一定温度で制御した状態で空回転させた場合、定着ローラからの伝熱により加圧ローラ温度は定着ローラ温度よりもほぼ 10 °C 低い温度に収束する。各条件において、定着ローラ温度センサ (Sensor 1)、加圧ローラ温度センサ (Sensor 2) の値をモニタリングしながら一定に収束したところで、1 枚ずつ紙を定着ニップ部に通紙し、紙が紙温度センサ (Sensor 3) を通過した期間における温度を記録した。

Table 3-2 実験条件

Exp. No.	Paper type	Printing speed [mm/s]	Fusing temperature [°C]
1	A	150	130 - 170
2	A	200	130 - 170
3	A	250	130 - 170
4	A	300	130 - 170
5	B	150	130 - 170
6	B	200	130 - 170
7	B	250	130 - 170
8	B	300	130 - 170
9	C	150	130 - 170
10	C	200	130 - 170
11	C	250	130 - 170
12	C	300	130 - 170
13	D	150	130 - 170
14	D	200	130 - 170
15	D	250	130 - 170
16	D	300	130 - 170

3.5 熱回路網モデル

Fig. 3-4 は、(a)定着ニップ部、(b)定着ニップ後の一次元熱回路網モデルである。定着ニップ部における各層は、定着ローラの弾性層、定着ベルトの基材層、弾性層、離型層、紙、加圧ローラの離型層、弾性層で構成されている。定着ローラの弾性層の内側にある芯金、加圧ローラの弾性層の内側にある芯金は、紙1枚通過における伝熱影響はほぼ無視できるほど小さいと考えられ、省略した。

熱回路網法とは、伝熱現象と電気回路との類似性に着目し、熱抵抗と熱容量で構成される熱回路に置き換えて伝熱現象をモデル化する手法である[3-7]。Fig. 3-4 (a) は定着装置のニップ部で定着ローラ、定着ベルト、加圧ローラによって紙が加熱される紙のモデル、(b) は定着後における紙と外気との対流熱伝達のモデルである。Table 3-3 に各部品の特性を示す。

熱抵抗 R は、各層の温度差を ΔT 、各層を流れる熱量を Q とすると、式(3-1)で表される。

$$R = \frac{\Delta T}{Q} \quad (3-1)$$

熱伝導率 λ 、断面積 A 、層厚 L 、温度差 ΔT の層を流れる熱量 Q は、式(3-2)で表される。

$$Q = \lambda \frac{A}{L} \Delta T \quad (3-2)$$

よって、熱抵抗 R は、式(3-3)で表される。

$$R = \frac{L}{\lambda A} \quad (3-3)$$




Fig. 3-4 一次元熱回路網モデル

Table 3-3 熱回路網モデルの各部品の特性

Component	Layer	Thickness [mm]	Thermal conductivity [W/(m·K)]	Specific heat [J/(kg·K)]
Fusing roller	Elastic layer	5	0.09	1550
Fusing belt	Substrate layer	0.09	0.20	1090
	Elastic layer	0.2	0.35	1030
	Release layer	0.03	0.25	1000
Pressure roller	Release layer	0.07	0.25	1000
	Elastic layer	3	0.38	1150

次に、定着ニップ後における紙と外気との対流熱伝達のモデルを以下のように考える．伝熱面積を A ，紙と外気との温度差を ΔT ，紙と外気との熱伝達率を α とすると，紙から外気への熱量 Q_{cv} は次式となる．

$$Q_{cv} = \alpha A \Delta T \quad (3-4)$$

熱伝達率 α の詳細については，次節 3.7 に記載した．式(3-4)を式(3-1)に代入すると，対流熱伝達による熱抵抗 R_{cv} は次式となる．

$$R_{cv} = \frac{1}{\alpha A} \quad (3-5)$$

また，ふく射熱伝達についても考慮する．伝熱面積を A ，表面温度を T_a ，外気温度を T_b とし，表面の放射率を ε ，形態係数を 1.0 としたとき，表面から放射される熱量 Q_{ra} は，式(3-6)で与えられる．

$$Q_{ra} = \varepsilon \sigma A (T_a^4 - T_b^4) \quad (3-6)$$

ここで， σ はステファン・ボルツマン定数である．式(3-6)を式(3-1)に代入すると，ふく射熱伝達の熱抵抗 R_{ra} は次のようになる．

$$R_{ra} = \frac{1}{\varepsilon \sigma A (T_a^2 + T_b^2)(T_a + T_b)} \quad (3-7)$$

熱容量 C は，密度 ρ ，比熱 c_p ，体積 V から，次式となる．

$$C = \rho c_p V \quad (3-8)$$

Fig. 3-4 (a) のニップ部における紙の i 層におけるのエネルギー方程式は，次式となる．

$$C_{Pa} \frac{dT_i}{dt} = Q_{Pa,i-1} - Q_{Pa,i} \quad (3-9)$$

ここで， C_{Pa} は紙の 1 層の熱容量， T_i は紙の i 層の温度， $Q_{Pa,i-1}$ は $i-1$ 層から i 層への熱量， $Q_{Pa,i}$ は i 層から $i+1$ 層への熱量である．式 (3-9) を紙の熱抵抗 R_{Pa} を用いて表すと，以下のようになる．

$$C_{Pa} \frac{dT_i}{dt} = \frac{T_{Pa,i-1} - T_{Pa,i}}{R_{Pa}} - \frac{T_{Pa,i} - T_{Pa,i+1}}{R_{Pa}} \quad (3-10)$$

ここで， R_{Pa} は紙の熱伝導率を用いて式 (3-3) により求められる．定着ローラ，定着ベルト，加圧ローラについてもエネルギー方程式は式 (3-10) と同様の形式となる．定着ベルトと紙との間，加圧ローラと紙との間には，接触熱抵抗 R_C が加わる．境界条件については，定着ローラの境界温度 T_{Fu} は Table 3-2 の定着温度で一定とし，加圧ローラの境界温度 T_{Pr} は定着温度より 10 °C 低い温度で一定とした．Fig. 3-4 (b) の定着ニップ後の紙の表面，裏面におけるエネルギー方程式はそれぞれ次式となる．

$$C_{Pa} \frac{dT_1}{dt} = \frac{T_A - T_{Pa,1}}{R_T} - \frac{T_{Pa,1} - T_{Pa,2}}{R_{Pa}} \quad (3-11)$$

$$C_{Pa} \frac{dT_n}{dt} = \frac{T_{Pa,n-1} - T_{Pa,n}}{R_{Pa}} - \frac{T_{Pa,n} - T_A}{R_B} \quad (3-12)$$

ここで， α_T は紙の表面と外気との熱伝達率， α_B は紙の裏面と外気との熱伝達率であり，外気の温度 T_A は 23 °C とした．

$$R_T = \frac{1}{\alpha_T A} + \frac{1}{\varepsilon \sigma A (T_{Pa,1}^2 + T_A^2)(T_{Pa,1} + T_A)} \quad (3-13)$$

$$R_B = \frac{1}{\alpha_B A} + \frac{1}{\varepsilon \sigma A (T_{Pa_n}^2 + T_A^2)(T_{Pa_n} + T_A)} \quad (3-14)$$

式 (3-1) ～ (3-14) に基づき, Fig. 3-4 の定着ローラの弾性層, 定着ベルトの基材層, 弾性層, 離型層, 紙, 加圧ローラの離型層, 弾性層をそれぞれ 10 層に分割して各層の熱抵抗, 熱容量を算出し, 数値計算を行った. 各部材の熱伝導率, 比熱, 接触熱抵抗, 熱伝達率, 紙が定着ニップを通過する前の初期温度 23 °C, 定着ローラ, 定着ベルト, 加圧ローラの初期温度を入力し, 式 (3-10) ～ (3-12) の時間微分に対して前進差分法を適用し, 時間発展で温度分布を求めた.




Fig. 3-5 紙温度予測プロセス

3.6 紙熱物性値予測のための ML アルゴリズム

Fig. 3-5 は, 熱回路網モデル, 実験, 機械学習モデルを組み合わせた紙温度予測プロセスである. 本手法で予測した紙の熱物性値を Fig. 3-4 の熱回路網モデルに入力することで, 学習実験条件以外の条件でも紙の温度を予測することができる. 詳細手順を以下のとおり記述する.

Step 1. 紙の熱伝導率, 比熱, 接触熱抵抗, 定着ニップ後の熱伝達率のランダムデータセットを作成する.

Step 2. Step 1 のランダムデータセットを熱回路網モデルに入力し、Table 3-4 の条件における定着ニップ後の紙温度を計算し、紙の熱伝導率、比熱、接触熱抵抗、熱伝達率と、紙温度とのデータセットを作成する。

Step 3. Table 3-5 に示すとおり、Step 2 で計算した紙温度のデータセットを入力、紙の熱伝導率、比熱、接触熱抵抗、熱伝達率のデータセットを出力として学習した機械学習モデルを構築する。

Step 4. Fig. 3-1 に示す定着装置を用いて、Table 3-4 の条件の実験により紙温度を実測する。

Step 5. Step 4 で得られた紙温度を、Step 3 で得られた機械学習モデルに入力し、紙の熱伝導率、比熱、接触熱抵抗、熱伝達率を出力し、予測値とする。

Step 6. Step 5 で得られた紙の熱伝導率、比熱、接触熱抵抗、熱伝達率を熱回路網モデルに入力し、Table 3-2 の実験条件における紙温度を予測する。また、Table 3-2 の実験条件における紙温度を実験により実測する。

Step 7. 予測された紙温度と実験による紙温度を比較し、本手法の予測精度を検証する。

Table 3-2 に示す全 80 種類の実験パターンのうち、Table 3-4 に示す 8 種類の実験パターンを用いて紙の熱物性値、紙温度を予測した。Table 3-2 の他の 72 の実験パターンは、予測精度の検証に使用された。

Table 3-4 機械学習の学習実験条件

Exp. No.	Paper type	Printing speed [mm/s]	Fusing temperature [°C]
1	A	150	140
2	A	300	140
3	B	150	150
4	B	300	150
5	C	150	140
6	C	300	140
7	D	150	150
8	D	300	150

Table 3-5 機械学習の学習実験における入力と出力

Input	Output
Paper temperature (Printing speed: 150 mm/s) Paper temperature (Printing speed: 300 mm/s)	Thermal conductivity Specific heat Thermal contact resistance Heat transfer coefficient

Table 3-6 に示す通り，ANN の基本構成は，前章の Fig. 2-2 と同じであるが，中間の隠れ層のニューロン数はそれぞれ 1000，500，250 とした．

Table 3-6 ANN の構成

Number of hidden layers	3
Number of neurons of each hidden layer	1000, 500, 250
Activation function on hidden layers	ReLU
Activation function on output layer	Linear
Optimizer	Adam

3.7 従来手法による紙の熱物性値予測

Fig. 3-2, Fig. 3-3 に示したように，紙は，繊維，表面コーティング，填料，水分などが複雑に混合されて構成されており，紙の種類によってこれらの配分量が異なり，この差異が熱物性値に影響し，印刷時の紙温度上昇にも影響する．例えば，表面コーティングが施され，表面が平滑な紙は，定着ベルトとの実接触面積が大きくなり接触熱抵抗が小さくなるため，温度上昇が大きくなる傾向がある．また，填料によって繊維間が充填されたり，繊維と填料との配分比率が変わることで，熱伝導率や比熱も変わる．また，常温常湿環境においては紙には数%の水分が含まれており，定着ニップ部における温度上昇に影響するだけでなく，定着ニップ後の水分蒸発による蒸発潜熱も紙温度低下に影響する．

しかし，紙の熱物性値を高精度に測定することは困難であるだけでなく，測定条件によって熱物性値は異なる．例えば，示差走査熱量計（DSC）により紙の比熱を測定するとき，長時間の加熱により水分の蒸発が起こり，比熱は温度によって変化する．一方，定着装置により加熱されるとき，例えばニップ幅が 10 mm，印刷速度が 200 mm/s であれば，加熱時間は 0.05 s となり極めて短時間で加熱され，その間は定着ニップ部に水分は留まっている可能性がある．

これらの要因により，本研究で提案した機械学習モデルと熱回路網モデルとの組み合わせによる手法と，従来手法との差異が存在すると考えられ，比較のために従来手法によって紙の熱物性値，熱伝達率を求めた．比較のための従来手法は，過去の論文のデータや提案された算出方法を用いた．熱伝導率や比熱など紙の熱物性を測定した論文はいくつか存在するが[3-6][3-7]，Lavrykov ら[3-6]の論文はサンプル数が多いため，この論文に記載されているデータから本研究で用いた紙種の熱物性値を予測した．

Lavrykov ら[3-6]は，ヒータとクーラの上に複数枚の紙を挟み，定常状態での上下の温度差，ヒータに通電する電力，紙の枚数，厚さから熱抵抗，熱伝導率を算出した．測定結果は Fig. 3-6 に示すように，紙の密度と熱伝導率の相関性を確認することができる．今回使用した Table 3-1 の Paper A, B, C, D の紙の密度も Fig. 3-6 にプロットすることにより，熱伝導率を算出した．




Fig. 3-6 紙の密度と熱伝導率の相関性

更に, Lavrykov ら[3-6]は, 紙の比熱についても熱伝導率測定と同じ装置を用いて測定したが, 測定方法は異なり, 紙の温度, ヒータ, クーラの時間変化と数値計算により求められた. 測定結果から, Fig. 3-7 に示す紙の灰分と比熱の相関性が確認された. 今回使用した Table 3-1 の Paper A, B, C, D の紙の灰分を Fig. 3-7 にプロットすることにより, 比熱を算出した.




Fig. 3-7 紙の灰分と比熱の相関性

定着部材と紙との接触熱抵抗については、佐野川[3-8]による次の近似式を用いた。

$$R = \frac{1}{\frac{1}{\frac{z_1}{k_1} + \frac{1}{h_0} + \frac{z_2}{k_2}} \frac{p}{\bar{H}} + \frac{\lambda}{z_1 + z_2} \left(1 - \frac{p}{\bar{H}}\right)} \quad (3-15)$$

$$\frac{1}{h_0} = 2.3 \times 10^{-5} \left(\frac{1}{k_1} + \frac{1}{k_2} \right) \quad (3-16)$$

ここで、 p は定着ニップ部の圧力、 $\bar{H}$ は定着ベルトの離型層の硬度、 z_1 は紙の表面粗さ（最大高さ）、 z_2 は定着ベルトの離型層の表面粗さ（最大高さ）、 k_1 は紙の熱伝導率、 k_2 は定着ベルトの離型層の熱伝導率、 λ は空気の熱伝導率である。

定着ニップ後の紙と外気との間の熱伝達率 α は、次式となる。

$$\alpha = \frac{Nu_x \lambda}{x} \quad (3-17)$$

ここで、 Nu_x は局所ヌッセルト数、 λ は空気の熱伝導率、 x は紙の搬送方向先端からの位置である。紙の代表温度は紙の先端から 30 mm の位置で測定し、1 枚の紙は定着ニップにより一定の熱流束で先端から後端まで加熱されるため、ここでは次式の局所ヌッセルト数[3-9]を用いた。

$$Nu_x = 0.458 Pr^{1/3} Re_x^{1/2} \quad (3-18)$$

ここで、 Pr は空気のプラントル数、 Re_x は局所レイノルズ数であり、次式となる。

$$Re_x = \frac{Ux}{\nu} \quad (3-19)$$

ここで、 U は紙に対する空気の相対速度であり、本実験の場合は印刷速度、つまり紙の搬送速度となる。 ν は空気の動粘度である。 Re_x が 3.2×10^5 以下であったため、層流熱伝達とした。

3.8 結果と考察


Table 3-7 に、機械学習モデルと熱回路網モデルとの組合せ手法（ML）によって予測した 4 種類の紙の熱伝導率、比熱、接触熱抵抗、熱伝達率と、従来手法（Conventional）で予測した値を示す。熱伝導率、熱伝達率については、ML により求めた値は、従来手法より大きい値となった。比熱については、ML により求めた値は、Lavrykov ら[3-6]の従来手法よりもやや小さくなり、接触熱抵抗については、大きな差は無かったが、佐野川[3-8]による従来手法は普通紙とコート紙との差は ML よりもやや大きかった。

Table 3-7 機械学習と従来手法による熱物性値，熱伝達率の比較


Paper type	Method	Thermal conductivity [W/(m·K)]	Specific heat [J/(kg·K)]	Thermal contact resistance [K/W]	Heat transfer coefficient [W/(m ² ·K)]
A	ML	0.53	1248	0.00024	40.1
	Conventional	0.10	1413	0.00029	6.0 - 8.4
B	ML	0.63	1289	0.00025	47.2
	Conventional	0.10	1406	0.00029	6.0 - 8.4
C	ML	0.56	1233	0.00021	34.4
	Conventional	0.13	1418	0.00018	6.0 - 8.4
D	ML	0.62	1217	0.00020	39.7
	Conventional	0.12	1531	0.00019	6.0 - 8.4

Fig. 3-8 は，Fig. 3-1 の Sensor 3 によって検知した紙温度の実測値を横軸に，ML によって予測した Sensor 3 の位置の紙温度を縦軸にプロットし，予測精度を検証した．実験条件は，Table 3-2 に示す 80 パターンであり，Paper A, B, C, D, 印刷速度 150, 200, 250, 300 mm/s のそれぞれについてプロットした．Paper B が最も予測精度が高く，Paper C が最も悪い結果となったが，いずれの紙種についても大きな差は無く，±6 °C 以内の誤差であった．学習実験条件においては，予測精度は最大±5 °C であったため，±1 °C に相当する過学習は含まれていると判断された．


Fig. 3-9 は，Fig. 3-1 の Sensor 3 によって検知した紙温度の実測値を横軸に，従来手法によって予測した Sensor 3 位置の紙温度を縦軸にプロットし，予測精度を検証した．実験条件は，Table 3-2 に示す 80 パターンであり，Paper A, B, C, D, 印刷速度 150, 200, 250, 300 mm/s のそれぞれについてプロットした．予測精度は，Paper A が±12 °C，Paper C が±10 °C であり，ML よりも劣位であった．印刷速度が 200 mm/s における予測精度は高いが，150 mm/s の場合は実測値よりも高く，300 mm/s の場合は実測値よりも低く予測しており，従来手法による予測値は，実測値よりも印刷速度依存性が高い．印刷速度が遅いほど定着ニップ部と紙との接触時間が長くなるため紙温度も上昇しやすいが，接触時間に対する紙温度上昇を実際よりも高く予測していた．Paper B, D についての予測精度は，それぞれ±18 °C，±22 °C であり，Paper A, C よりも更に劣位であった．また，いずれの印刷速度に対しても実測値より低く予測していた．その理由としては，紙の厚さの影響があると考えられる．Paper B, D は，Paper A, C よりも厚い紙であり温度上昇は薄い紙に比べて小さいが，厚さ依存性を実際よりも高く予測していたことになる．また，Paper A, B は普通紙，Paper C, D はコート紙であり，コート紙は表面が平滑で，定着ベルトとの接触熱抵抗が小さく，温度上昇が普通紙よりも大きい傾向にあることは予測できていた．




(a) Paper A



(b) Paper B




(c) Paper C




(d) Paper D


Fig. 3-8 機械学習モデルと熱回路網モデルの組合せ手法 (ML) による予測精度




(a) Paper A



(b) Paper B



(c) Paper C



(d) Paper D

Fig. 3-9 従来手法による予測精度

Fig. 3-10～Fig. 3-17 は、ML と従来手法の紙温度プロファイルの比較である。Table 3-2 の実験条件のうち、印刷速度 200 mm/s、定着温度 150 °C の温度プロファイルを示す。(a) は定着ニップ部における紙温度プロファイル、(b) は定着ニップ後における紙温度プロファイルを示す。“Top” は紙表面の温度，“Middle” は紙中間層の温度，“Back” は紙裏面の温度を示す。


Fig. 3-10(a) と Fig. 3-11(a), Fig. 3-12(a) と Fig. 3-13(a), Fig. 3-14(a) と Fig. 3-15(a), Fig. 3-16(a) と Fig. 3-17(a) との比較から、ML の Top と Middle, Back と Middle の温度差は、従来手法よりも小さい。ML による紙の熱伝導率は、従来手法よりも小さく予測していることが要因である。熱伝導率が小さい場合には、印刷速度が速いほど、つまり定着ベルトと紙との接触時間が短いほど、定着ニップ部において紙中間層の温度が温度上昇しにくいいため、定着ニップ後に温度低下しやすい。逆に印刷速度が遅ければ、紙中間層も温度上昇し、定着ニップ後に温度低下しにくい。例えば、Fig. 3-11(b) の 0.00 s においては Top と Middle, Back と Middle の差は大きい、Top の温度は直後に急激に低下した。印刷速度がこれより速ければ、定着ニップ部での接触時間は 0.05 s よりも短

く、Top と Middle, Back と Middle の差は更に大きくなり、定着ニップ後における温度低下も更に大きくなる。


この傾向は紙厚が厚くなるほど影響が大きくなる。従来手法の Fig. 3-11, Fig. 3-13 を比較すると、Top と Middle, Back と Middle の差は、薄い Paper A よりも厚い Paper B の方が大きく、定着ニップ後における温度低下は Paper B の方が大きい。Fig. 3-9 において、従来手法が接触時間に対する紙温度上昇を実際よりも高く予測していた要因が紙の熱伝導率にあり、更に Fig. 3-9(b), (d) において、厚い Paper B, Paper D では、紙温度を実温度より低く予測していた要因も熱伝導率にある。従来手法で熱伝導率を小さく予測していた要因は、測定方法にあると考えられる。Lavrykov ら [3-6] は、ヒータとクーラの間に複数枚の紙を挟み、定常状態での上下の温度差、ヒータに通電する電力、紙の枚数、厚さから熱伝導率を算出する際に、紙と紙との接触熱抵抗は無いと仮定した。しかし、実際には紙と紙との間に接触熱抵抗は存在する。紙を複数枚重ねて熱伝導率を算出する際に、紙と紙との接触熱抵抗を考慮して熱伝導率を補正した場合は、紙と紙との接触熱抵抗を考慮せず熱伝導率を補正しなかった場合に比べて 1 枚の熱伝導率は高く算出される。そのため、従来手法では熱伝導率を実際よりも低く算出していた可能性がある。

そこで、熱伝導率測定時の紙と紙との間の接触熱抵抗の影響について考察した。Table 3-7 より、Paper A の Lavrykov ら [3-6] の手法によって求めた熱伝導率は $0.1 \text{ W}/(\text{m} \cdot \text{K})$ である。紙の厚さは $123 \mu\text{m}$ であり、紙を 10 枚重ねた場合の熱抵抗は、式(3-3)より、 0.0123 K/W となる。紙と定着ベルトとの接触熱抵抗は、 0.00029 K/W であるが、定着ベルトの変形はほぼ無いと仮定すると、紙と紙との間の接触熱抵抗は、2 倍の 0.00058 K/W となる。紙 10 枚分の抵抗 0.0123 K/W から、10 枚分の紙と紙との間の接触熱抵抗 0.0058 K/W を除くと、 0.0065 K/W となり、式(3-3)より補正後の熱伝導率は、 $0.189 \text{ W}/(\text{m} \cdot \text{K})$ となる。更に、Lavrykov ら [3-6] の測定時における圧力は定着ニップ部の $1/2$ とすると、10 枚分の紙と紙との間の接触熱抵抗は 0.0116 K/W となり、同様の方法により補正後の熱伝導率は、 $1.757 \text{ W}/(\text{m} \cdot \text{K})$ となり、ML で予測した熱伝導率よりも大きくなる。このように紙と紙との間の接触熱抵抗は熱伝導率の測定に大きく影響し、また圧力にも大きく依存するため、Table 3-7 における ML と従来手法との熱伝導率の差は、紙と紙との間の接触熱抵抗の影響が大きいと考えられる。しかし、測定時における紙と紙との間の接触熱抵抗を高精度に測定することは困難である。

比熱、接触熱抵抗については、ML と従来手法とで大きな差は無く、比熱、接触熱抵抗の差は温度プロファイルには明確に表れてはいなかった。




(a) 定着ニップ部




(b) 定着ニップ後

Fig. 3-10 MLによるPaper Aの紙温度プロファイル予測




(a) 定着ニップ部




(b) 定着ニップ後

Fig. 3-11 従来手法によるPaper Aの紙温度プロファイル予測




(a) 定着ニップ部




(b) 定着ニップ後

Fig. 3-12 ML による Paper B の紙温度プロファイル予測




(a) 定着ニップ部




(b) 定着ニップ後

Fig. 3-13 従来手法による Paper B の紙温度プロファイル予測




(a) 定着ニップ部




(b) 定着ニップ後

Fig. 3-14 ML による Paper C の紙温度プロファイル予測




(a) 定着ニップ部




(b) 定着ニップ後

Fig. 3-15 従来手法による Paper C の紙温度プロファイル予測




(a) 定着ニップ部




(b) 定着ニップ後

Fig. 3-16 ML による Paper D の紙温度プロファイル予測



(a) 定着ニップ部




(b) 定着ニップ後


Fig. 3-17 従来手法による Paper D の紙温度プロファイル予測

次に定着ニップ後における温度プロファイルの差について考察する。Fig. 3-10(b)と Fig. 3-11(b), Fig. 3-12(b)と Fig. 3-13(b), Fig. 3-14(b)と Fig. 3-15(b), Fig. 3-16(b)と Fig. 3-17(b)との比較から、ML の紙温度低下速度は従来手法よりも大きくなった。ML の熱伝達率は従来手法よりも大きいことが要因である。前述したとおり、実際の紙には数%の水分が含まれ、定着ニップ部で加熱され、定着ニップ後に蒸発する。その際、蒸発潜熱が奪われるため、対流熱伝達とふく射熱伝達によって計算される温度低下よりも、実際の温度低下は大きいと考えられる。しかし、ここでの従来手法は水分蒸発は考慮していなかった。大杉らは、定着ニップ後の温度をサーモグラフィで測定し[1-13]、定着ニップ出口において、急激に温度低下していることが確認された。


従来手法において、蒸発潜熱を考慮した場合の定着ニップ後における紙温度低下への影響について考察した。水の蒸発潜熱は 2257 kJ/kg であり、Paper A において 0.25 s 間において水分量が 1% 低下したと仮定した。Paper A の坪量は 103 g/m^2 であり、水分蒸発量は 1.03 g 、蒸発潜熱は 2325 J となる。Fig. 3-18(c)に定着ニップ後における紙温度プロファイルを示す。Fig. 3-18(a)は ML, (b)は蒸発潜熱を考慮しない場合の従来手法であり、それぞれ Fig. 3-10(b), Fig. 3-11(b)と同一であり、(c)は蒸発潜熱を考慮した場合の従来手法である。(c)蒸発潜熱を考慮した場合には、(b)蒸発潜熱を考慮しない場合と比べて定着ニップ後の紙温度低下は大きくなり、(a)ML と近い結果となった。この結果から、Table 3-7 における ML と従来手法との熱伝達率の差は、蒸発潜熱の影響が大きいと考えられる。他の紙種 Paper B, C, D においても水分蒸発量が同程度であれば、紙温度低下も同程度である。ただし、定着ニップ後における水分蒸発量、蒸発時間は過去の知見からの仮定であるため、より詳細なモデルを構築する際には、定着ニップ後における紙水分量変化の実測が必要となる。



(a) ML



(b) 蒸発潜熱を考慮しない場合の従来手法



(c) 蒸発潜熱を考慮した場合の従来手法

Fig. 3-18 定着ニップ後における紙温度プロファイルへの蒸発潜熱の影響

3.9 結言

本章では、従来から用いられている定着ニップ部を表す熱回路網モデルをベースに、機械学習を組み合わせて定着プロセス後の紙温度を予測する手法を提案した。紙温度を入力、紙の熱物性値を出力とする機械学習モデルは、実験から得られた定着プロセス後の紙温度を入力することで、熱物性値を出力することが可能となった。ML で得られた各紙の熱物性値と、従来手法で得られた熱物性値とを熱回路網モデルに入力し、定着プロセス後の紙温度を予測し、実験の測定結果と比較した。従来手法の予測誤差は最大 ± 22 °Cであったが、ML は最大 ± 6 °Cの予測精度が得られた。従来手法とML との予測精度差の要因は、紙の熱伝導率、定着ニップ後における紙に含まれる水分の蒸発潜熱の影響が大きく、測定が困難である対象に対してML の有効性を確認した。また、これまでもML のみを用いた紙温予測法は提案されていたが、検証実験より多くの学習実験が必要であった。これに対し、本手法は、8 条件の学習実験から 72 条件の検証実験を予測した。この手法は、紙温度だけでなく、トナー温度やトナー定着性も予測するモデルに展開可能であると考えられ、次章で検証を行う。

一方、今回構築した手法は、定着ニップ後におけるセンサ位置のみでの予測精度を検証しており、それ以外での検証はできていない。また、熱回路網モデルは定着ニップ部や定着ニップ後のすべての現象をモデル化できていないため、定着ニップ部での紙の温度上昇プロファイル、紙の断面方向の温度分布、紙からの水分蒸発影響などが実際と異なる可能性がある。現状では、限られた領域の温度を高い精度で予測するのに有効な方法ではあるが、次章で扱うニップ部におけるトナー溶解性を予測するためには、改めて学習実験が必要であると考えられる。

3.10 参考文献

- [3-1] H. AL-Rubaiey, P. Oittinen, “Thermal Behavior of Paper in Contact Fusing Technology,” *Journal of Imaging Science and Technology*, Vol. 52, No. 3, pp. 030507-1-03507-10, 2008.
- [3-2] D. J. Sanders, D. F. Rutland, W. K. Istone, “Effect of Paper Properties on Fusing Fix,” *Journal of Imaging Science and Technology*, Vol. 40, No. 2, pp. 175-179, 1996.
- [3-3] S. Oohara, Y. Hayama, H. Tanigawa, and T. Tsuruta, “Prediction of Paper Curl Generated by Fusing Process,” *Journal of the Imaging Society of Japan*, Vol. 52, No. 6, pp. 85-92, 2013.
- [3-4] A. Bandyopadhyay, B. V. Ramarao, and Eric C. Shih, “Transient Response of a Paper Sheet Subjected to a Traveling Thermal Pulse: Evolution of Temperature, Moisture and Pressure Fields,” *Journal of Imaging Science and Technology*, Vol. 45, No. 6, pp. 598-608, 2001.
- [3-5] S. Simula, Jukka A. Ketoja, K. Niskanen, “Heat transfer to paper in a hot nip,” *Nordic Pulp and Paper Research Journal*, Vol. 14, No. 4, pp. 273-278, 1999.
- [3-6] S. A. Lavrykov, B. V. Ramarao, “Thermal Properties of Copy Paper Sheets,” *Drying Technology*, Vol. 30, pp. 297-311, 2012.
- [3-7] K. Hirose, T. Fukue, F. Nakagawa and R. Ito, “Basic Study on Transient Temperature Response of Papers in a Thermal Transfer Printer,” *Proc. ASME InterPACK2013*, IPACK2013-73088, 2013.
- [3-8] 佐野川 好母, “金属接触面における伝熱に関する研究(第 4 報, 接触面の表面あらさの形状・うねりの影響と接触熱抵抗の近似計算法),” 日本機械学会論文集, 第 33 巻, 第 251 号, pp. 1131-1137, 1967.
- [3-9] 日本機械学会, “伝熱工学資料(改訂第 5 版),” 丸善出版, pp. 26-29, 2009.

第4章 機械学習と熱回路網法によるトナー溶融性予測

4.1 緒言

第2章では排紙部におけるトナーブロッキングの発生を予測するために、排紙部紙温度を機械学習により予測した。第3章では、機械学習モデルと熱回路網モデルとの組合せにより、少ない実験回数で多くの条件における紙温度を予測する手法を開発した。

一方、第1章では、商用印刷については、印刷される紙種が豊富になってきていることを記述した。豊富な紙種に対して、トナーブロッキングの発生を予測できるが、ブロッキングの発生を防ぐためには、第2章で記述した冷却装置におけるファンやチラーの出力を制御するか、定着装置における定着温度を下げる必要がある。定着温度を下げればトナーブロッキングの発生を防ぐことができるが、過剰に定着温度を下げた場合にはトナー溶融性が不足し、第1章で記述したコールドオフセットが発生する。

逆に、定着温度を引き上げれば十分なトナー溶融性が得られ、コールドオフセットの発生は防ぐことができるが、トナーブロッキングが悪化するだけでなく、Table 1-1 に記述された省エネルギーや環境への影響が悪化する。よって、定着温度は紙種ごとに最適な範囲に設定にすることが望ましい。


これまでの定着装置におけるトナー溶融解析に関して、解析モデルの開発や定着プロセスの測定が行われてきた。大西らは、紙表面粗さとトナーの動的粘弾性を考慮した定着強度の解析モデルを構築した[4-1]。三矢は、供給熱量と圧力に対して、トナーが吸収するエネルギーを計算した[4-2]。山岸らは、熱伝導だけでなくトナーの粘弾性も考慮した定着ニップのモデルベース開発 (MBD) を行った[4-3]。長谷部は、定着ニップ内においてトナーを積層した粒子として扱い、温度により変化するトナーの粘弾性特性とニップ圧を考慮したトナーの変形解析をおこなった[4-4]。

これまでに様々な解析手法や、解析モデルが提案されてきたが、近年の商用印刷で需要があるように、複数の紙種に対して定着装置におけるトナー溶融性や、定着温度範囲、つまりコールドオフセットが発生しない温度範囲を高精度に予測する手法は提案されていなかった。第3章で温度予測を行った紙と同様、トナーについても定着ニップ内における溶融性を熱物理モデルを構築して予測することやモデル化を行うことは難しい。

Fig. 4-1 に正常に定着した画像と、コールドオフセットが発生した画像を示す。正常に定着した画像は均一にトナーが紙に定着しているが、コールドオフセットが発生した画像はトナーが抜けている箇所が多く存在する。定着温度が低く、トナーが溶融不足により紙との接着力が得られず、定着ベルトに転移しているため、画像上のトナーが抜け落ちている。

Fig. 4-2 (a)に示すように、溶融前のトナーは平均粒径が $5\sim7\ \mu\text{m}$ の粒子であり、紙には静電気力で付着している。また、顔料、決着樹脂、外添剤などの複数材料から構成されている。Fig. 4-2 (b) は定着後のトナーであり、粒子の界面はやや残るが、ほぼ空隙が無く溶融している。このように、トナー粒子の形状や、トナー同士の接触、トナーと定着ベルトとの接触状態は定着ニップ内において変化し、また定着ベルトとの接触熱抵抗も変化するため、トナーの溶融変化を表す高精度の解析モデルは大変複雑になる。


第2章，第3章で示したように，モデル化が難しい課題に対して機械学習を適用することは有効であると考えられる．しかし，機械学習モデルを構築するために多くの学習実験が必要であるならば，実機評価によって定着温度範囲を求めた方が精度が高く，信頼性も高いということになる．また，経験則から紙特性ごとの予測もある程度は可能である．よって，本章では，第3章で開発した機械学習モデルと熱回路網モデルを組み合わせた手法により，少ない学習実験回数によりトナー溶解性や，定着温度範囲を高精度に予測する手法を開発することを目的とする．




(a) 正常に定着した画像

(b) コールドオフセットが発生した画像


Fig. 4-1 定着画像のサンプル



(a) 溶融前のトナー粒子



(b) 定着後のトナー



(c) コールドオフセットが発生した画像のトナー




Fig. 4-2 コールドオフセットのSEM観察

4.2 実験装置

実験は、第3章と同様の定着温度 (Fusing temperature) と印刷速度 (Printing speed) を任意の値に制御可能であり、ヒータへの通電量制御装置と、回転駆動制御装置を含む定着装置の単体試験機を用いて行った。概略図を Fig. 4-3 に示す。定着装置には、定着ローラ温度センサ (Sensor 1)、加圧ローラ温度センサ (Sensor 2) が搭載されており、第3章で用いた紙温度センサ (Sensor 3) は使用していない。

なお、以降で用いる定着温度（Fusing temperature）とは、定着ベルトの目標温度であり、定着ローラ温度センサ（Sensor 1）が目標温度に追従するようにヒータへの通電を制御することは第3章と同様である。




Fig. 4-3 実験装置の概要

4.3 紙種と紙物性

本章の目的は、異なる印刷条件における紙上のトナー温度応答、熔融状態の予測方法を開発することであるため、本実験では、Table 4-1 に示す坪量，厚さ，平滑度，表面コーティング，密度，灰分量の異なる Paper A, B, C, D の4種類の紙で実験を行った．第3章の紙と同一である．これらの紙の特性は、定着装置から紙とトナーへの伝熱特性，定着ニップ内での紙とトナーの温度上昇に影響を与える．

Table 4-1 紙種と紙物性

Paper type	Basis weight [g/m ²]	Thickness [μm]	Smoothness [s]	Surface coating	Density [kg/m ³]	Ash content (wt%)
A	103	123	66	Non-coated	840	19.0%
B	154	184	40	Non-coated	840	19.3%
C	98	100	788	Coated	980	18.8%
D	161	171	731	Coated	940	14.2%

4.4 実験条件

実験では、Table 3-2 に示す 16 パターンとした。紙は Paper A, B, C, D の 4 種類、印刷速度は 150, 200, 250, 300 mm/s の 4 パターンとした。加圧ローラ内部には加熱源がないが、加圧ローラ温度は定着ローラ温度よりもほぼ 10 °C 低い温度に収束する。各条件において、定着ローラ温度センサ (Sensor 1)、加圧ローラ温度センサ (Sensor 2) の値をモニタリングしながら一定に収束したところで、イエロー、マゼンタの未溶融トナーを均一に付着させた紙をニップ部に通紙し、コールドオフセットの発生有無を確認した。定着温度は 5 °C ずつ上昇させ、コールドオフセットが発生しない下限の定着温度を記録し、下限の定着温度以上を定着温度範囲とした。

Table 4-2 実験条件

Exp. No.	Paper type	Printing speed [mm/s]
1	A	150
2	A	200
3	A	250
4	A	300
5	B	150
6	B	200
7	B	250
8	B	300
9	C	150
10	C	200
11	C	250
12	C	300
13	D	150
14	D	200
15	D	250
16	D	300

4.5 熱回路網モデル

Fig. 4-4 は、定着ニップ部の一次元熱回路網モデルである。定着ニップ部の層は、定着ローラの弾性層、定着ベルトの基材層、弾性層、離型層、紙、加圧ローラの離型層、弾性層で構成されており、トナー層については省略されているが、定着ベルトの離型層とトナーとの接触については、トナーの接触熱抵抗値を用いる。トナー層を省略した理由については、トナーの熱伝導率、比熱、接触熱抵抗

を全て考慮すると、予測する熱物性値が紙の熱物性値も含めて6種類となり、機械学習プログラムが収束しない可能性があったためである。また、4紙種の中で最も薄いPaper Dの厚さは100 μm であるが、トナーの厚さは7 μm であり、紙に対して十分薄いため大きな影響は無いとした。以降は、紙表面温度とトナー温度とが一致しているとする。また、定着ニップ内のみの紙、トナー温度上昇、トナー熔融現象をモデル化しており、定着ニップ後については省いている。

熱抵抗を求める式や、エネルギー方程式については式(3-1)～(3-3)、(3-8)～(3-10)と同一であり、熱回路網モデルの各部品の特性は、Table 3-3と同一である。





Fig. 4-4 定着ニップ部の一次元熱回路網モデル


4.6 トナー熔融特性

定着温度範囲を予測するためには、トナー温度に対するトナー熔融性を表す指標が必要となる。トナーの熔融性を表す指標はいくつか存在するが、定着温度範囲と相関性のある指標として、レオメー


タで測定した動的粘弾性があり、動的粘弾性は貯蔵弾性率、損失弾性率、貯蔵弾性率と損失弾性率の比である損失正接で表される。トナーの貯蔵弾性率が低いほど、トナーと紙との濡れ性、接着性が高くなり、貯蔵弾性率が高いほどトナーと紙との接着性が低くなり、コールドオフセットが発生する。定着温度範囲の下限、つまりコールドオフセットが発生しない温度範囲の下限温度における貯蔵弾性率は 1×10^5 Pa とされている [4-5] [4-6] [4-7]。Fig. 4-5 に、本実験で使用したトナーの (a) 貯蔵弾性率、(b) 損失弾性率、(c) 損失正接を示す。(b) 損失弾性率、(c) 損失正接は本研究では用いないが、参考のために併せて記載した。貯蔵弾性率が 1×10^5 Pa になる温度は 89.8°C であり、定着ニップ内でトナー温度（本章では紙表面温度）が 89.8°C 以上になっていれば、コールドオフセットは発生しないとした。また、定着温度範囲とは、紙とトナーが定着ニップ部を通過する前の定着ベルトの目標温度の範囲を指しており、紙とトナーが定着ニップ部を通過したときの定着ニップ部における定着ベルト温度、トナー温度、紙表面温度とは異なる。



(a) 貯蔵弾性率



(b) 損失弾性率



(c) 損失正接

Fig. 4-5 トナーの動的粘弾性




Fig. 4-6 定着温度範囲の予測プロセス

4.7 定着温度範囲予測のための ML アルゴリズム

Fig. 4-6 は、熱回路網モデル、実験、機械学習モデルを組み合わせた定着温度範囲の予測プロセスである。本手法で予測した紙の熱伝導率、比熱、接触熱抵抗、トナーの接触熱抵抗を、再度 Fig. 4-4 の熱回路網モデルに入力することで、学習実験条件以外の条件でもトナーの温度を予測し、定着温度範囲を予測することができる。第 3 章と基本的な手法は同一であるが、トナー温度を予測するプロセスが異なる。

Step 1. 紙の熱伝導率、比熱、接触熱抵抗、トナーの接触熱抵抗のランダムデータセットを作成する。

Step 2. Fig. 4-3 に示す定着装置を用いて、Table 4-2 の実験条件における実験によりトナーがコールドオフセットせずに正常に定着する定着温度範囲（下限温度）を測定する。

Step 3. Step 1 のランダムデータセットを熱回路網モデルに入力し、Table 4-3 の学習実験条件における紙表面（トナー）温度を計算し、紙の熱伝導率、比熱、接触熱抵抗、トナーの接触熱抵抗と、紙表面（トナー）温度とのデータセットを作成する。このときの定着温度（定着ベルトの目標温度）は、Step 2 で実測した定着温度範囲の下限温度、つまりコールドオフセットが発生しない定着温度とする。

Step 4. Table 4-4 に示すとおり，Step 3 で計算した紙表面（トナー）温度のデータセットを入力，紙の熱伝導率，比熱，接触熱抵抗，トナーの接触熱抵抗のデータセットを出力として学習した機械学習モデルを構築する．

Step 5. 前節で求めたトナーが紙に定着するトナー温度 89.9 °C を，Step 4 で得られた機械学習モデルに入力し，紙の熱伝導率，比熱，接触熱抵抗，トナーの接触熱抵抗を出力し，熱物性値の予測値とする．

Step 6. Step 5 で得られた紙の熱伝導率，比熱，接触熱抵抗，トナーの接触熱抵抗を熱回路網モデルに入力し，Table 4-2 の実験条件における紙表面（トナー）温度を予測し，紙表面（トナー）温度が 89.8 °C となる定着温度（定着ベルトの目標温度）を求め，トナーがコールドオフセットしない定着温度範囲（下限温度）を予測する．

Step 7. Step 6 で予測された定着温度範囲（下限温度）と，Step 2 で得られた実験による定着温度範囲（下限温度）を比較し，本手法の予測精度を検証する．

Table 4-2 に示す全 16 種類の実験パターンのうち，Table 4-3 に示す 4 種類の実験パターンを用いて紙の熱伝導率，比熱，接触熱抵抗，トナーの接触熱抵抗を予測した．Table 4-2 の他の 12 の実験パターンは，予測精度の検証に使用される．

ANN の構成は，第 3 章と同じである．

Table 4-3 機械学習の学習実験条件

Exp. No.	Paper type	Printing speed [mm/s]
5	B	150
8	B	300
13	D	150
16	D	300

Table 4-4 機械学習の学習実験における入力と出力

Input	Output
Toner temperature (Printing speed: 150 mm/s) Toner temperature (Printing speed: 300 mm/s)	Thermal conductivity Specific heat Thermal contact resistance Heat transfer coefficient

4.8 従来手法によるトナー，紙の熱物性値予測

紙の熱伝導率，比熱，接触熱抵抗は第 3 章で求めた Table 3-7 の値と同じであり，定着ニップ後については考慮しないため，熱伝達率は用いない．接触熱抵抗については，佐野川の式[3-8]を用いた

が、トナーが存在する面については、定着後の画像面の表面粗さ（最大高さ）を用いて算出した。

Fig. 4-7 にレーザ顕微鏡による定着後のトナー表面の観察結果を示す。Paper A, Paper B は普通紙であり、繊維の折り重なりの上にトナーを付着させているため、10 μm 程度の凹凸がある。Paper C, Paper D はコート紙であり、平滑な表面の上にトナーを付着させているため、凹凸は最大 5 μm 程度である。紙上のトナー厚さは平均 7 μm であり、マゼンタトナーとイエロートナーを同量重ねている。普通紙とコート紙とで表面粗さが異なり、この差が定着ニップ部における接触熱抵抗の差要因になると考えられる。




Fig. 4-7 定着後の紙上トナーの表面形状

4.9 結果と考察

Table 4-5 に、機械学習モデルと熱回路網モデルとの組合せ（ML）によって予測した 4 種類の紙の熱伝導率、比熱、接触熱抵抗、トナーの接触熱抵抗と、従来手法（Conventional）で予測した値を示す。ML で求めた熱物性値は、普通紙の Paper A, B は同じ値、コート紙の Paper C, D は同じ値とした。紙の密度、灰分、表面の平滑度は大きく変わらないためである。

熱伝導率は、ML の値が従来手法より大きく、普通紙よりもコート紙で差が大きくなった。比熱については、ML により求めた値は、従来手法よりも普通紙で大きく、コート紙で逆にやや小さくなった。

た．紙の接触熱抵抗については，ML がやや大きく，トナーの接触熱抵抗については，ML と従来手法とで大きな差はなかった．

Table 4-5 ML と従来手法による紙の熱伝導率，比熱，接触熱抵抗，トナーの接触熱抵抗の比較

Paper type	Method	Thermal conductivity [W/(m·K)]	Specific heat [J/(kg·K)]	Thermal contact resistance of paper [K/W]	Thermal contact resistance of toner [K/W]
A	ML	0.14	1792	0.00038	0.00021
	Conventional	0.10	1413	0.00029	0.00021
B	ML	0.14	1792	0.00038	0.00021
	Conventional	0.10	1406	0.00029	0.00021
C	ML	0.32	1403	0.00028	0.00018
	Conventional	0.13	1418	0.00018	0.00017
D	ML	0.32	1403	0.00028	0.00018
	Conventional	0.12	1531	0.00018	0.00018




Fig. 4-8 ML による定着温度範囲の下限温度予測

Fig. 4-8 は，実測したトナーの定着温度範囲の下限温度を横軸に，機械学習モデルと熱回路網モデルの組合せ（ML）によって予測したトナーの定着温度範囲の下限温度を縦軸にプロットし，予測精度を検証した．実験条件は，Table 4-2 に示す 16 パターンであり，紙種は Paper A, B, C, D, 印刷速度は 150, 200, 250, 300 mm/s についてプロットした．Paper B, Paper D については学習実験に

含まれているため予測精度は $\pm 5^{\circ}\text{C}$ であったが、学習実験に含まれていない Paper A, C についても予測精度は $\pm 6^{\circ}\text{C}$ 以内であった。この場合は、 $\pm 1^{\circ}\text{C}$ に相当する過学習は含まれていると判断された。定着温度範囲の下限温度を求めるための実測は 5°C 刻みで判定したため、 5°C 未満の誤差が生じることがある。





Fig. 4-9 従来手法による定着温度範囲の下限温度予測


Fig. 4-9 に従来手法 (Conventional) による予測精度を示す。予測精度は $\pm 19^{\circ}\text{C}$ 以内であり、特に普通紙の Paper A, B の予測精度は Paper C, D の予測精度に対して低かった。Paper A, B の定着温度範囲の予測は、実測よりも低く予測していた。普通紙は表面の平滑性が低く、トナーと紙との接着性や溶融性にバラツキが生じる。僅かでも定着していないトナーが存在すると、コールドオフセット発生と判定される。しかし、従来手法ではトナーの面内平均温度を予測している。そのため、予測した定着温度範囲の下限温度は、実測よりも低い温度となった。つまり、従来手法は低い定着温度でもトナーは定着すると予測したが、実際には普通紙においては予測よりも高い温度でないと定着しない結果になった。一方、コート紙は表面が平滑であるため、そのようなバラツキは小さい。

それに対し、ML は普通紙のトナーと紙との接着性や溶融性のバラツキがある中で、コールドオフセットが僅かでも発生しない紙表面 (トナー) 温度を 89.9°C とし、その時の定着温度との関係性を学習し、モデル構築することにより、従来手法のような誤差は小さくすることが可能となった。

このように ML はトナーの定着性の平均値ではなく、僅かでも定着せずにコールドオフセットが発生する場合の最悪値で学習している。物理モデルは面平均で考えられており、この差によって Table 4-5 における物性が ML と従来手法で異なる結果となった。




(a) ML




(b) Conventional

Fig. 4-10 Paper A の紙温度プロファイル予測



(a) ML




(b) Conventional


Fig. 4-11 Paper B の紙温度プロファイル予測

Fig. 4-10～Fig. 4-13 は、ML と従来手法の温度プロファイルの比較である。Table 4-2 の実験条件のうち、印刷速度 200 mm/s の結果である。(a) は ML、(b) は従来手法の温度プロファイルを示す。定着温度は(a)、(b)で同一である。“Top” は紙表面（トナー）の温度，“Middle” は紙中間層の温度，“Back” は紙裏面の温度を示している。

Fig. 4-10, Fig. 4-11 における(a)、(b)の比較から、普通紙において ML の Top の温度は、従来手法よりもやや低くなった。この差は、ML で予測した熱伝導率、比熱、紙の接触熱抵抗は従来手法より大きいことが要因である。前述したように、従来手法は紙表面（トナー）温度をやや高く予測するが、この予測温度は面内平均温度であり、紙の凹部においてはトナーとの界面温度が低くなっている箇所があると考えられる。




(a) ML




(b) Conventional

Fig. 4-12 Paper C の紙温度プロファイル予測



(a) ML



(b) Conventional

Fig. 4-13 Paper D の紙温度プロファイル予測

Fig. 4-12, Fig. 4-13 における (a), (b) の比較から、コート紙において Top の温度は、ML と従来手法とはほぼ同じ温度であった。ML で予測した熱伝導率は従来手法より大きい、ML の比熱は従来手法より小さく、結果的にほぼ同じ温度になったと考えられる。Paper C, D はコート紙であり、普通紙に比べてコールドオフセットのバラツキが小さく、予測精度も高くなったと考えられる。

4.10 結言

本章では、従来から用いられている熱回路網モデルをベースに、機械学習を用いてトナー温度、定着温度範囲を予測する手法を提案した。紙表面（トナー）温度を入力、紙の熱伝導率、比熱、接触熱抵抗、トナーの接触熱抵抗を出力とする ML モデルは、トナーがコールドオフセットしないときの定

着温度における紙表面（トナー）温度を入力することで、紙の熱伝導率、比熱、接触熱抵抗、トナーの接触熱抵抗を出力し、予測した。ML で得られた熱物性値と従来法で得られた熱物性値を熱回路網モデルに入力し、異なる紙種、印刷条件における定着温度範囲の下限温度を予測し、実測結果と比較した。その結果、従来手法の予測誤差は最大 ± 19 °Cであったが、ML は最大 ± 6 °Cの予測精度が得られた。また、これまでも ML のみを用いた紙温予測法は提案されていたが、学習実験が多く必要という欠点があったのに対し、学習した 2 種類の紙種以外の 2 種類の紙種についても予測可能であった。ML はトナーと紙との接着性や溶融性のバラツキがある中で、コールドオフセットが僅かでも発生しない場合の紙表面（トナー）温度と定着温度との関係性を学習し、モデル構築することにより、従来手法よりも高精度に予測が可能となった。

4.11 参考文献

- [4-1] T. Onishi, K. Kato, M. Kouno, H. Eguchi, Y. Kobaru and Y. Yoda, “Toner Fix Simulation in Fuser Process,” *Journal of the Imaging Society of Japan*, Vol. 52, No. 6, pp. 515-522, 2013.
- [4-2] T. Mitsuya, “Considerations on the Level of Heat and Work Energy in the Nip Region for Toner Fusing,” *Journal of Imaging Science and Technology*, Vol. 56, No. 3, pp. 030506-1-030506-5, 2012.
- [4-3] 山岸 義弘, “トナー粘弾性に着目した 1D-CAE による定着ニップ機能のモデルベース設計,” 日本画像学会誌, 第 60 巻, 第 2 号, pp. 162-168, 2021.
- [4-4] 長谷部 恵, “定着トナー溶融プロセスの数値シミュレーション,” 日本画像学会誌, 第 49 巻, 第 3 号, pp. 182-190, 2010.
- [4-5] 川村 貴生, 白井 亜弥, 藤野 香, 高松 大, “トナー,” 特許第 6079921 号, 2017.
- [4-6] T. Kawamura, A. Shirai, K. Fujino, “Toner,” U.S. Patent, US9740122B1, 2017.
- [4-7] 前井 宏之, トナー, 特許第 6879100 号, 2021.

第5章 結論

本研究では、今後の電子写真方式商用印刷の付加価値として拡大してくと考えられる印刷速度の高速化と多種多様なメディア対応に着目し、それに伴って多種多様化する定着プロセスの熱課題に対応可能な製品開発に貢献することを目的として、機械学習を用いて電子写真プロセスにおける紙、トナー温度を高精度に予測できる手法を開発した。電子写真プロセスは、帯電、露光、現像、転写、定着のプロセスから構成され、同時に紙搬送が行われ、それぞれが互いに影響を及ぼし合う複雑なシステムであり、また、粉体であるトナーや、温湿度に敏感な紙を扱うため、理論的に解析することが困難であった。そのため、試作、実機による評価や、詳細なモデル化と膨大な数値計算によるシミュレーションが行われてきた。それに対し、本研究では、機械学習モデル、または従来の物理モデルと機械学習とを組み合わせたモデルにより、定着プロセス後の紙、トナー温度を、高精度に予測できる手法を提案した。それによって、従来の複雑な物理モデルや、機械学習の欠点であった多くの学習実験を必要とせず、目的の温度を高精度に予測可能となった。

排紙部紙温度予測において、第一の機械学習モデルとして FNN モデルを適用し、 $\pm 5\text{ }^{\circ}\text{C}$ の排紙部紙温度の予測精度が得られた。従来は紙の坪量でカテゴリー分けしており、坪量のみ入力した場合の予測精度は、 $\pm 9\text{ }^{\circ}\text{C}$ であったが、坪量、厚さ、平滑度を入力することで、過学習を抑制し、予測精度は $\pm 5\text{ }^{\circ}\text{C}$ に向上し、目標値以内となった。第二の機械学習モデルとして LSTM モデルを用い、印刷開始後 20 枚の温度データから、最大 500 枚までの紙温度を予測することが可能となった。LSTM モデルと比較するための同じ条件における FNN モデルの予測精度は $\pm 6\text{ }^{\circ}\text{C}$ であったが、LSTM モデルでは $\pm 4\text{ }^{\circ}\text{C}$ に向上した。第三の機械学習モデルとして、印刷時における定着装置内の部材温度、ヒートパイプ温度プロファイルから紙物性を予測できるモデルを構築した。坪量、厚さの予測精度は、 $\pm 10\%$ 以内であったが、平滑度の予測精度は 10%以内には収まらず、過学習と判断された。平滑性に影響する温度検知のサンプリングやデータの前処理方法を改善することで、過学習を抑制する余地があると考えられる。

一方、排紙部紙温度予測モデルは、適切な入力を選択することにより必要な精度は得られたが、機械学習のみによる予測であり、定着装置温度、印刷速度、紙物性を組み合わせた多くの学習実験が必要とすることが欠点であった。そこで、従来から用いられている定着ニップ部、定着ニップ後を表す熱回路網モデルをベースに、機械学習を組み合わせ定着プロセス後の紙温度を予測する手法 (ML) を開発した。従来手法の予測誤差は最大 $\pm 22\text{ }^{\circ}\text{C}$ であったが、ML は最大 $\pm 6\text{ }^{\circ}\text{C}$ の予測精度が得られた。また、8 条件の学習実験から 72 条件の検証実験の予測が可能となった。従来手法と ML との予測精度差の要因は、紙の熱伝導率、定着ニップ後における紙に含まれる水分の蒸発潜熱の影響が大きく、測定が困難である対象に対して ML の有効性を確認した。

更に、熱回路網モデルと機械学習とを組み合わせ手法 (ML) をベース、トナーがコールドオフセットしない定着温度範囲を予測する手法を開発した。従来手法の予測誤差は最大 $\pm 19\text{ }^{\circ}\text{C}$ であったが、ML は最大 $\pm 6\text{ }^{\circ}\text{C}$ の予測精度が得られた。また、学習した 2 種類の紙種以外の 2 種類の紙種についても予測可能であった。従来手法はトナー温度を面内平均で計算しているが、ML は僅かでも定着せず

にコールドオフセットが発生する場合の最悪値で学習しており，前モデルと同様，測定が困難である対象に対して ML は有効であった．

以上により，いずれのモデルにおいても従来手法よりも高い予測精度が得られたが，機械学習の課題は前述したとおり多くの学習実験を必要とすることであり，学習データ取得コストに対する予測可能範囲を拡大させることが，機械学習の利用価値を高めることに繋がる．今後は，本論文の提案手法の製品開発，設計プロセスへの展開，製品搭載へ向けて，複数の機種や紙種についての更なる追加検証と，製品展開に適した機械学習アルゴリズムの開発を継続する．第 1 章で記述したように，電子写真方式商用印刷は今後も付加価値の向上，市場の発展が見込める分野である．この分野への機械学習の導入は，顧客要望への対応性向上，短納期での製品開発に繋がり，更なる業界発展に貢献できると考えられる．

付録

Table 6-1 に各章で用いたモデルの比較を示す．第 2 章では物理モデルは用いず，機械学習のみを用いて排紙部における紙温度予測，紙物性予測を行った．モデルは，FNN，LSTM，FNN（紙物性予測）の 3 種類であり，物理モデルを用いていないため，坪量，平滑度といった物性値も入出力可能である．予測精度は高く，モデル構築は容易であるが，多くの学習実験が必要であった．

第 3 章，第 4 章で用いた機械学習（FNN）と熱回路網法との組合せモデルは，予測精度が高く，学習実験が少なく，紙熱物性値の測定が不要であることがメリットであるが，学習実験と物理モデル構築はどちらも必要であり，複雑なシステムでは物理モデルも複雑になる可能性がある．従来手法は熱回路網モデルのみを用いており，学習実験は不要であるが，紙熱物性値の測定が必要であり，条件によっては予測精度が悪い場合がある．

Table 6-1 各章でのモデル比較

	第 2 章 排紙部紙温度予測			第 3 章 定着ニップ後紙温度予測		第 4 章 定着温度範囲予測	
	機械学習			機械学習	従来手法	機械学習	従来手法
モデル	FNN	LSTM	FNN (紙物性予測)	機械学習 (FNN) 熱回路網法	熱回路網法	機械学習 (FNN) 熱回路網法	熱回路網法
入力	紙物性 坪量 厚さ 平滑度 センサ検知温度 印刷速度		センサ検知温度 印刷速度	実測した紙温度	紙熱物性値 熱伝導率 比熱 紙接触熱抵抗 熱伝達率	実測した定着温度 範囲	紙熱物性値 熱伝導率 比熱 紙接触熱抵抗 トナー接触熱抵抗
出力	排紙部紙温度		紙物性 坪量 厚さ 平滑度	紙熱物性値 定着後の紙温度	定着後の紙温度	紙熱物性値 定着後のトナー温度	定着温度範囲
メリット	モデル構築が容易 高精度予測が可能 熱物性値以外の入出力も可能			高精度予測が可能 多くの学習実験は不要 熱物性値の測定は不要	学習実験は不要	高精度予測が可能 多くの学習実験は不要 熱物性値の測定は不要	学習実験は不要
デメリット	多くの学習実験が必要			学習実験と物理モデル構築が必要	予測精度が低い 熱物性値の測定が困難	学習実験と物理モデル構築が必要	予測精度が低い 熱物性値の測定が困難

記号一覧

T	: 温度 [°C]
Q	: 単位時間あたりの熱量 [W]
R	: 熱抵抗 [K/W]
λ	: 熱伝導率 [W/(m·K)]
k	: 式(3-15), (3-16)における接触部材の熱伝導率 [W/(m·K)]
α	: 熱伝達率 [W/(m ² ·K)]
A	: 面積 [m ²]
V	: 体積 [m ³]
L	: 層厚 [m]
ϵ	: 放射率
σ	: シュテファン・ボルツマン定数 [W/(m ² ·K ⁴)]
ρ	: 密度 [kg/m ³]
c	: 比熱 [J/(kg·K)]
C	: 熱容量 [J/K]
t	: 時間 [s]
p	: 定着ニップ部圧力 [Pa]
$\bar{H}$	: 硬度
z	: 表面粗さ [m]
Nu	: ヌッセルト数
Pr	: プラントル数
Re	: レイノルズ数
U	: 流速 [m/s]
ν	: 動粘度 [m ² /s]

研究業績

- [6-1] T. Hase, S. Kawasaki, E. Dursunkaya, T. Ishikura, K. Hemmi, K. Yamazaki, S. Kuramoto, K. Kato, K. Fushinobu, “Temperature Prediction Modeling in Production Printing System by Using Machine Learning,” *Proc. ISTP31*, ISTP091, 2020.
- [6-2] 長谷 岳誠, 加藤 弘一, 山崎 公晴, 辺見 香理, 伏信 一慶, 倉本 信一, “画像形成装置及び推定装置,” 公開特許公報 2022-063052, 2020.
- [6-3] T. Hase, T. Ishikura, S. Kuramoto, K. Kato and K. Fushinobu, “Paper property and temperature prediction modeling in production printing system by using machine learning,” *Proc. 2nd ACTS*, 50623, 2021.
- [6-4] 長谷 岳誠, 加藤 弘一, 伏信 一慶, 倉本 信一, “画像形成装置及び推定装置,” 出願番号 2021-160445, 2021.
- [6-5] T. Hase, S. Kawasaki, E. Dursunkaya, T. Ishikura, K. Hemmi, K. Yamazaki, S. Kuramoto, K. Kato, and K. Fushinobu, “Paper Temperature Prediction Modeling in Production Printing System by Using Machine Learning,” *Journal of Imaging Science and Technology*, Vol. 66, No. 3, pp. 030507-1-030507-10, 2022.
- [6-6] 石倉 匠, 長谷 岳誠, 倉本 信一, 加藤 弘一, 伏信 一慶, “電子写真方式の印刷における用紙温度の LSTM Network による予測法の開発,” 日本機械学会熱工学コンファレンス 2022 講演論文集, F223, 2022.
- [6-7] T. Hase, T. Ishikura, S. Kuramoto, K. Kato, and K. Fushinobu, “Development of Paper Temperature Prediction Method in Electrophotographic Processes by Using Machine Learning and Thermal Network Model,” *Journal of Imaging Science and Technology*, Vol. 68, No. 1, 2024 [in press].
- [6-8] T. Hase, T. Ishikura, S. Kuramoto, K. Kato, and K. Fushinobu, “Development of Toner Melting Prediction Method in Electrophotographic Processes by Using Machine Learning and Thermal Network Model,” *Proc. ISTP33*, ISTP155, 2023 [in press].

謝辞

本研究を進める上で、お世話になった全ての方々に感謝の意を表します。

指導教員である伏信一慶教授には、終始ご指導いただき心より感謝申し上げます。本研究の基盤である機械学習と電子写真技術との融合に関する考え方や、研究の方針に関して大変貴重なご助言を賜りました。

ご多忙のところ、本論文の主査を引き受けていただいた笹部崇准教授、副査として貴重なご助言を賜りました岡村哲至教授、奥野喜裕教授、西田佳史教授に心より感謝申し上げます。

加藤弘一特任講師には、東京工業大学と株式会社リコーとの共同研究を通じた学位取得のきっかけや、様々な人脈との繋がりを与えていただきました。倉本信一特別研究員には、幅広い経験からの研究方針や論文作成に関するご助言や、関連研究調査において大変お世話になりました。機械学習チームの石倉匠さんとは数多くの技術ディスカッションを行い、プログラミングや実験に関する連携を通して豊富なデータを取得することができ、本研究の成果に繋げることができました。感謝申し上げます。

佐藤真美補佐員には、学会発表、論文投稿など様々な手続きで大変お世話になりました。

株式会社リコー第三画像技術開発室の皆様には、本研究に関する社外での取り組みの許可を与えていただき、業務と学業を両立させることができました。また、皆様の豊富な商品開発の知見は、常に研究を進める上での支えになりました。感謝申し上げます。

最後に、東京工業大学の先生方、研究室の皆様、株式会社リコーの皆様、ご協力いただいた全ての皆様に、この場を借りて感謝いたします。