新進気鋭

機械学習を活用した金属積層造形の プロセスパラメータ設計

鈴木飛鳥*

shinshinkiei

1. はじめに

この度は第32回日本金属学会奨励賞を頂戴しましたこ と,関係各位の皆様に厚く御礼申し上げます.また,受賞に 際して、本記事を執筆する機会をいただきました. 拙い内容 で大変恐縮ではございますが,私が現在取り組んでいる研究 や今後の展望に関して紹介させていただきます.私は2016 年9月に名古屋大学大学院工学研究科マテリアル理工学専 攻にて村田純教教授,湯川 宏助教の指導の下で学位を取得 した後,2017年4月より名古屋大学大学院工学研究科物質 プロセス工学専攻にて小橋 眞教授,高田尚記准教授の研究 室にて助教を務めております. 学生時代は, 金属系の水素透 過膜の水素透過特性を水素の化学ポテンシャルをもとに解析 する研究を実施しておりました.助教に着任以降は金属積層 造形をはじめとする粉末冶金プロセスの研究に従事し、金属 材料のポーラス化、複合化、組織制御に関する研究を行って おります. その中で, 機械学習・深層学習などのデータ科学 を活用したプロセス設計や特性予測を行うことが現在の研究 のメインテーマとなっております. そこで本記事では、私が 助教着任後に行ってきた研究の一つとして、金属積層造形の プロセスパラメータ設計における機械学習の活用について紹 介させていただきます.

2. 研究背景

金属積層造形(Additive Manufacturing; AM)は,設計デ ータに基づき金属原料を一層ずつ積層することで目的とする

形状の金属部材を得る方法である(1)(2). 従来の鋳造, 鍛造, 焼結, 塑性加工, 切削などを経るプロセスと比較して複雑な 形状を有する部材を製造することができるとともに、複数の パーツからなる部材を一体で製造することができる⁽³⁾.そう した部材は医療分野や航空機分野で実用化されている⁽⁴⁾⁽⁵⁾. 金属 AM の中で最も代表的な方式の一つが、レーザ粉末床 溶融結合(Laser Powder Bed Fusion; L-PBF)法である⁽²⁾. L-PBF 法では、原料となる金属粉末を造形エリアに均一な 厚さ(数十µm程度)で敷設し,目的とする箇所へレーザを照 射することで局所的に溶融・凝固させる. 一層でのレーザ照 射が終了した後,再び粉末の敷設とレーザ照射を行う.この ステップを幾度も繰り返すことで設計した部材とほぼ同一形 状の部材を製造することができる. こうしたニアネットシェ イプ造形は難加工材料に適用した際にその優位性が高い.例 えば、超硬合金は WC 硬質粒子と Co バインダー相からなる 材料であり、高硬度と優れた耐摩耗性を併せ持つため、切削 工具や金型に利用されている材料である.現在は原料となる 粉末を焼結し,所定の形状に切削することで部材を作製して いる⁽⁶⁾.しかしながら、その優れた特性ゆえに超硬合金を製 品の形に切削する際に長期間を要する(7). そうした問題を解 決する上で、L-PBF 法は有効である. L-PBF 法によりニア ネットシェイプで造形することで、最終仕上げのみで製品を 得ることができるため、製造期間を大幅に短縮できる.加え て、従来製造が困難であったインラインセンシング金型など の高機能部材製造を可能とする⁽⁸⁾.以上の観点から,WC/ Co 超硬合金の L-PBF 造形に取り組んだ.

しかしながら,WC/Co超硬合金のL-PBF造形において は大きな課題がある.図1に従来の焼結法およびL-PBF法

^{*} 東海国立大学機構名古屋大学大学院工学研究科物質プロセス工学専攻;助教(〒464-8603 名古屋市千種区不老町1)

Design of Process Parameters in Metal Additive Manufacturing Utilizing Machine Learning; Asuka Suzuki(Department of Materials Process Engineering, Graduate School of Engineering, Nagoya University, Tokai National Higher Education and Research System, Nagoya)

Keywords: additive manufacturing, machine learning, process informatics, composite, cemented carbide 2023年3月23日受理[doi:10.2320/materia.62.464]



図1 (a) 従来の焼結法および(b) レーザ粉末床溶融結合(L-PBF)法(レーザ出力(P):195W,走査速度(v):300 mm·s⁻¹,スポット径(σ):150μm)により作製した WC/Co 超硬合金の代表的な微視組織を表す SEM 像⁽⁹⁾.

によって作製した WC/Co 超硬合金の微視組織を示す⁽⁹⁾. 図 1(a)に示されるように、従来の焼結法で作製した超硬合金 では高い体積率で存在する WC 硬質粒子が均一に分散し, Coバインダー相によって結合された組織形態を呈する.こ うした微視組織に起因して、上述の高硬度・耐摩耗性といっ た特性が発現する.しかしながら,L-PBF法で作製した超 硬合金は、従来の焼結法で作製したものとは異なる不均質な 組織を呈する(図1(b)). この組織は大きく分けて2種類の 組織領域に大別することができる.1つはWC硬質粒子と Co相を主な構成相とし、比較的従来の超硬合金の組織に近 い領域(WC/Co二相領域)である⁽⁹⁾⁽¹⁰⁾. もう1つはWC粒 子や Co相がほとんど確認されず、微細な組織を呈する領域 (WC 分解領域)である. この WC 分解領域では, W₂C や η-W₃Co₃C などの相が存在することが報告されている⁽¹¹⁾⁽¹²⁾. こうした組織領域の形成は、超硬合金の高硬度・耐摩耗性を 損なう要因となる.したがって、超硬合金のL-PBF 造形で は、その微視組織を制御しながら造形を達成する必要があ る. そのためには, L-PBF 法のプロセスパラメータ(レーザ 出力,走査速度,スポット径,etc.)の最適化が必要不可欠 である.本研究では、機械学習などのデータ科学を活用する ことで効率的にプロセスパラメータを最適化することに取り 組んだ⁽¹³⁾.

3. 画像認識による組織情報の定量化

機械学習を用いるために, 組織情報を定量化する必要があ

る.本研究の場合,WC分解領域を抑制することが目的のた め、SEM 像における WC 分解領域の面積率(A_d)が定量情報 としては有効である. Ad を定量化するためには, WC 分解 領域とそれ以外の領域に分ける二値化処理を実行すればよ い. しかしながら,図1(b)に示されるように,WC分解領 域とWC二相領域はそれぞれに明部・暗部を含むため、階 調に閾値を設定する一般的な二値化処理ではその判別が困難 である. そこで本研究では, 階調だけでなく, 組織の形態情 報も基準として組織を判別できる畳み込みニューラルネット ワーク(Convolutional Neural Network; CNN)による画像認 識を活用した. CNN は教師あり機械学習手法の一つであ り、組織画像とそれに対応する情報(特性などの数値情報や セグメントした画像)を学習させる.本研究で言えば、組織 画像とそれを各領域(WC分解領域,WC/Co二相領域)にセ グメントした画像を学習させる. その後, 学習に用いていな い画像を入力すると、学習に基づく基準によって組織を判別 し, セグメンテーションを行う. よって, この方法を用いる ためには、教師画像とそれをセグメントした画像を用意する 必要がある.しかしながら,超硬合金の組織画像を教師デー タとした場合、その画像を手作業でセグメントする必要があ り、CNN を用いる利点が少ない.そこで教師画像を簡便に 取得するために、本研究ではシングルトラック試験を行った.

シングルトラック試験(図2(a))は、バルク体や粉床にレ ーザを一度だけ走査するものであり、L-PBF 法においては レーザ照射による溶融挙動や組織変化を基礎的に調べるため によく行われる.本研究では,超硬合金の焼結体にレーザを 種々の条件で走査する実験を行った.その結果,図2(c)に 示す組織画像を得た⁽¹³⁾.このとき、図2(b)に示すように、 レーザ照射中心部に近い箇所では、L-PBF 造形体における WC 分解領域と似た組織形態が認められた.実際にこの領域 を解析すると、 W_2C や η - W_3Co_3C の存在が認められた. レ ーザ照射中心部付近は特に温度が上昇するため、温度上昇と WC 分解領域の形成には密接な関係があると考えられる. C-Co-W 三元系状態図では、本研究で用いた原料粉末組成 では WC の溶融温度まで W_2C や η - W_3CoC_3 の形成は予想さ れない⁽¹¹⁾. また, Scheil の条件に基づく非平衡凝固シミュ レーションにおいても W_2C の形成は予想されない⁽¹⁰⁾. 一方, L-PBF 造形体や WC 分解領域の組成分析の結果から、レー ザ照射によってCoやCが気化することが示されてい る⁽¹¹⁾⁽¹²⁾.こうした組成シフトを考慮すると、非平衡凝固シ ミュレーションにおいて $W_2C \approx \eta - W_3C_0C_3$ の形成は予想さ れる⁽¹⁰⁾⁽¹¹⁾. すなわち, WC も溶融とCo, C の気化に伴う 組成シフトを経た後、L-PBF プロセスの速い冷却速度に起 因した非平衡凝固過程によって W₂C や η-W₃Co₃C が形成す ると考えられる.一方,レーザ照射中心部から離れると,温 度はWCの融点に達しないため、Coのみが溶融し、WC/ Co二相組織が維持される. つまり, L-PBF 造形体で見られ た2つの組織領域は、領域ごとに到達温度に差が生じ、異 なる溶融・凝固挙動を示した結果として形成したものと考え られる.シングルトラック試験により得られた組織画像で



図2 (a) シングルトラック試験の模式図および(b) WC/Co 超硬合金のレーザ照射部断面の代表的な微視組織.(c) 種々の条件でシングルトラック試験を行った WC/Co 超 硬合金の SEM 像および手動で領域をセグメントした画 像⁽¹³⁾.

は、このような2つの組織領域が明瞭に判別でき、手作業 でセグメントすることも比較的容易である.そこで、こうし た画像を図2(d)のようにWC分解領域、WC/Co二相領 域、欠陥の3つの領域にセグメントし、教師画像として用 いた(実際の教師画像は図2(c),(d)も含めて13組の画像を 用いた).

レーザ出力, 走査速度, スポット径をプロセスパラメータ として、約30条件で超硬合金のL-PBF 造形を行った.造形 体の組織を SEM により観察し、上述のシングルトラック試 験の組織画像を学習させた CNN により組織のセグメンテー ションを行った. その結果の代表例を図3に示す⁽¹⁰⁾⁽¹³⁾.シ ングルトラック試験の組織画像を教師データとしても、概ね 正しいセグメントが行えることが明らかとなった. シングル トラック試験による教師データ収集は、金属積層造形による 他の材料系に応用が可能である.得られたセグメント画像か ら, A_dを定量化し、レーザ出力、走査速度、スポット径に 対してプロットしたものを図3(b)に示す⁽¹⁰⁾.図中の×印で 示されるプロットは、レーザに投入エネルギーが小さかった ため、造形時に固化しなかった条件である. 〇印で示される プロットは, 立方体形状の試料が作製可能であった試料であ り、プロットの色でAdを区別している. これらの結果か ら,低出力,低走査速度,大スポット径において,試料が固 化するとともに Ad が小さい傾向が確認できる.

4. 回帰・分類分析による定量化情報の解析と最適条 件推定

組織情報を定量化できれば、様々なデータ解析の手法を適 用することができる.その一例を図4に示す⁽¹³⁾.例えば、



図3 (a) 種々の条件でL-PBF 法により作製した WC/Co 超 硬合金の SEM 像および(b) シングルトラック試験のデ ータを学習させた畳み込みニューラルネットワーク (CNN)により領域をセグメントした画像.(c) WC 分解 領域の面積率(A_d)とP, v, σの関係⁽⁹⁾.

レーザ出力,走査速度,スポット径を説明変数, A_d を目的 変数とした線形重回帰分析を行い,各説明変数の回帰係数を 求めた結果を図4(a)に示す.レーザ出力は正,走査速度と スポット径は負の回帰係数を持つことが分かる.このことか ら A_d は,高レーザ出力,低走査速度,小スポット径ほど大 きくなる傾向がある.加えて,この回帰係数の絶対値から, 各説明変数の重要度が理解できる.すなわち,レーザ出力が 最も A_d に与える寄与が大きく,走査速度が最も寄与が小さ いことが分かる.

一方,こうした定量情報から好適なレーザ条件の範囲を推 定することも可能である。例えば、レーザ条件をサポートベ クターマシン(SVM)により,A_d=0.1を閾値として、分類 した結果を図4(b)に示す。図中に示される平面がSVMに よる分類境界を表す。主にレーザ出力とスポット径を重視し た分類が行われていることが分かる。この分類は、上述の回 帰分析において走査速度の重要度が最も低いことと対応す る。一方、図4(c)に試料が固化するかどうかを基準として



図4 (a) $A_d \geq P$, v, σ の関係を重回帰分析した際の回帰係数⁽¹³⁾. (b) $A_d < 0.1/A_d \ge 0.1$ or (c) unconsolidated/consolidated を基準としたサポートベクターマシン(SVM)によるレーザ条件の分類および(d) それらの $\sigma = 150 \ \mu m$ における断面⁽¹³⁾. (e) SVM による推奨条件の一つ($P = 50 \ W$, $v = 10 \ mm \cdot s^{-1}$, and $\sigma = 150 \ \mu m$)で造形した WC/Co 超硬合金の微視組織と CNN によるセグメント画像⁽¹³⁾.

レーザ条件を分類した結果を示す. 試料の固化の可否に対し ては、レーザ出力、走査速度、スポット径のすべてが寄与す る分類が行われている.このように、分類の基準によってレ ーザ条件の寄与度は大きく異なる.この二つの分類結果を重 ね合わせ、スポット径を150 µm に固定した平面を表示した ものを図4(d)に示す.この図において、横軸に垂直な線が A_dを閾値とした分類,斜めの線が試料の固化を基準とした 分類である.よって、図中の太線で囲まれた三角形内のレー ザ条件では、試料が固化するとともに、A_dを0.1以下に低減 できることを示している. そこで, この三角形内の条件で追 加の造形を行った.その中でレーザ出力 50 W, 走査速度 10 mm·s⁻¹で造形した試料の断面 SEM 像と CNN によるセグ メンテーションの結果を図4(e)に示す.この条件において 試料は固化し、かつ WC 分解領域の Ad はほぼ 0 であること が確認された.このように、CNNによる定量情報とSVM による分類分析を活用することで、超硬合金の微視組織を制 御できるレーザ条件の最適化に成功した.一方で,図4(e) に示される組織には不均一性が認められ,局所的に WC 粒 子が認められない領域や WC 粒子が成長・粗大化した領域 が観察される.WC粒子が認められない領域はCoリッチの 液相が原料粉末間の隙間や原料粉末内に存在した気孔に流入 し, 凝固した箇所であると考えられる.また,WC粒子が成 長・粗大化した箇所は、プロセス中にレーザ照射中心部に近

かった箇所と推定される. それにより,局所的に高い温度に 到達し, Co リッチの液相を介した原子拡散が促進され, WC 粒子が成長・粗大化したと考えられる. こうした組織の 均一化は,今後の課題である.

5. 移動熱源シミュレーションによる温度場解析

上述のように、機械学習やデータ解析の手法を活用することは、画像解析の効率化、レーザパラメータの重要度解析、 最適レーザ条件探索などに有効である。一方で、データ科学 手法は総じて帰納的な方法論である。すなわち、データ科学 手法は総じて帰納的な方法論である。すなわち、データに包 含される傾向から、レーザパラメータという説明変数とA_d という目的変数間の相関関係を導いている。しかしながら、 データ科学手法のみでは、「なぜA_dに対してレーザ出力の 寄与が最も大きく、走査速度の寄与が最も小さいのか」とい った原理を理解することは困難である。こうした原理を理解 するためには、物理的なモデルに基づく演繹的な方法論、す なわちシミュレーションが有効と考えられる。

シングルトラック試験の結果より,WC分解領域はレーザ 照射中心部付近に形成される.これは、レーザ照射によって 温度がWCの融点以上に到達することに起因すると考えら れる.すなわち、レーザパラメータと微視組織の相関関係に は到達温度という因子が密接に影響していると考えられる. そこで本研究では、移動熱源モデルによる温度場解析を試みた。移動熱源モデルとしては、移動する点熱源を仮定する Rosenthalの式が広く用いられている⁽¹⁴⁾⁻⁽¹⁸⁾.しかしながら、本研究ではレーザ出力と走査速度に加えてスポット径の寄与も解析するため、点熱源を仮定するモデルでは不十分である。一方、EagerとTsaiはガウス分布型のエネルギー分布をもつ移動熱源による温度場解析のモデルを提案している⁽¹⁹⁾.本研究で用いた積層造形装置においてもレーザのエネルギー分布はガウス分布に従うため、本モデルが有効と考えた。EagerとTsaiによる温度場 $T(x, y, z, \tau)$ は以下により定式化される。

$$T(x, y, z, \tau) - T_0 = \frac{P}{\pi \rho c \sqrt{4\pi\alpha}} \int_0^{\tau} \times \frac{\exp\left\{-\frac{(x - v\tau')^2 + y^2}{4\alpha(\tau - \tau') + 2(\sigma/4)^2} - \frac{z^2}{4\alpha(\tau - \tau')}\right\}}{\sqrt{(\tau - \tau') \left\{2\alpha(\tau - \tau') + (\sigma/4)^2\right\}}} d\tau'$$

ここで、 T_0 は基準温度、Pは熱源の出力、rは密度、cは比 熱, α は熱拡散率, vは熱源の移動速度, σ はスポット径(熱 源のエネルギーが最大値の1/e²になる位置で規定した円の 直径), x, y, zは空間座標, τ は時間, τ' は τ に至るまでの時 間をそれぞれ表す.モデルの概略図を図5(a)に示す.本モ デルでは、半無限固体を仮定し、z≤0の領域全体に固体が 存在する.ガウス分布型の熱源は x 方向に一定速度 v で移動 する. このモデルでは、固体の溶融や液相の流動は解析でき ないため、得られる温度場は定量的には実験と一致しないと 考えられる.一方で、レーザパラメータ P, v, σ が温度場に 与える影響について半定量的に議論することが可能である. 図 5(b)に代表座標(x₀, 0, 0)における温度と時間の関係を示 す.ここでは、基準となるレーザ条件として、(i)(P, v, σ) =(150 W, 100 mm·s⁻¹, 150 µm)を設定し, そこから走査速 度を半分(条件(ii)),スポット径を半分(条件(iii)),レーザ 出力を2倍(条件(iv))にした条件をそれぞれ解析した.縦軸 の温度は条件(i)における最高到達温度で規格化している. また, 横軸が0のとき熱源の中心と代表座標の位置が一致 する.条件(i)に対して走査速度を半分にした条件(ii)では, 全体的に温度変化が緩やかになったものの、最高到達温度は 条件(i)と比べてほとんど変化しない.一方で,スポット径 を半分あるいはレーザ出力を2倍にした条件(iii), (iv)では 最高到達温度が約2倍になることが分かる.条件(iii)と(iv) については、図5(c)-(f)に温度場を示す.この温度場は、 熱源の中心が代表座標の位置と一致した時間における温度場 を x-y 平面および z-y 平面上にそれぞれ表示したものであ り、最高到達温度に対して、0.8倍、0.6倍、0.4倍となる位 置がコンター色の境界と対応する.この結果から、これら2 つの条件では、最高到達温度はほぼ同じである一方、高い温 度に到達する空間的範囲が条件(iv)の方が広いことが分か る.以上をまとめると、走査速度を低下させても最高到達温 度にほとんど寄与しない、スポット径を絞るあるいはレーザ 出力を増加させると最高到達温度が大きく上昇する、レーザ 出力を増加させた場合の方が高い温度に到達する空間的範囲



図5 (a) Eager と Tsai⁽¹⁹⁾によるガウス分布型のエネルギー 分布を有する移動熱源モデルの模式図. (b) 種々の条件 下での(x_0 , 0, 0)における規格化温度と時間の関係⁽¹³⁾. 規格化温度は,各条件における温度を条件(i) P=150W, v=100 mm·s⁻¹, $\sigma=150$ µm における最高到達温度 で除したものである. $\tau=x_0/v$ における(c), (d) z=0mm ε (e), (f) $x=x_0$ での断面における温度のコンター 図⁽¹³⁾.条件は(c), (e) (P, v, σ) = (300 W, 100 mm·s⁻¹, 75 µm である.



図 6 温度場および WC 分解領域の形成に及ぼす P, v, σ の寄 与の模式図⁽¹³⁾.

が広いことが明らかとなった.

これらの結果から, A_dに与えるレーザ条件の影響は図6 に示した模式図を用いて考える.まず,議論を簡略化するた めWC分解領域は到達温度がWCの融点を超えた範囲で形 成されると考える(厳密には,温度上昇に伴うCoやCの気 化に伴う組成のシフトも考慮する必要がある).ある条件で WCの融点に到達しなかったと仮定すると,そこからレーザ 出力を低下させても最高到達温度は WC の融点に達しず, WC 分解領域も形成しない.一方,スポット径を低減あるい はレーザ出力を増加させると,最高到達温度が増加し,WC の融点を超える領域が生じる.このとき,レーザ出力を増加 させた場合の方がより広い範囲で WC 融点を超過すると考 えられ,スポット径を減らした場合に比べて広い範囲に WC 分解領域が形成される.以上のことから,A_dに対してレー ザ出力の寄与が最も大きく,走査速度の寄与が最も小さいと いうデータ分析の結果を理解できると考えられる.

6. おわりに

本稿では、筆者が行ってきた機械学習を活用した金属積層 造形のパラメータ設計について概説した.機械学習手法は、 Python ライブラリやオープンソースコードが充実してお り、比較的容易に実装することができる.したがって、材料 工学・科学に対して適用する上では、現象、データ、手法を 理解した上で適切な機械学習手法を選択することが重要であ る.また、機械学習手法のみでは原理を明らかにすることは できない.しかしながら、帰納的に得られる重要度などの情 報は原理を考えるヒントになる.そうしたヒントをもとに、 実験・シミュレーションと組み合わせて活用していくことが 重要と考えている.

本稿では紹介しなかったが、筆者は金属積層造形によって 造形できる複雑形状の構造体の特性を機械学習を活用して解 析する研究にも取り組んでいる.将来的には、ナノ・ミクロ な組織制御とマクロな構造体形状の最適化といったマルチス ケールでの構造最適化を通して高機能な材料・部材を創製す る指針を確立したいと考えている.

本研究を遂行するにあたり,名古屋大学大学工学研究科 小橋 眞教授,高田尚記准教授,あいち産業科学技術総合セ ンター加藤正樹主任研究員,梅田準史氏,フジミインコーポ レーテッド伊部博之氏に多大なる協力を頂いた.また,機械 学習による解析は,名古屋大学大学院生の柴勇輔君の尽力に よるものである.本稿で紹介した内容は,科学技術交流財団 の知の拠点あいち重点研究プロジェクト第 II~IV 期,科学 研究費補助金の学術変革領域(A)公募研究(JP22H05281), 科学技術振興機構(JST)の戦略的創造研究推進事業(ACT-X, JP21460460)の支援を受けた.ここに特記して謝意を記す.

文 献

- (1) 京極秀樹,池庄司敏孝:図解 金属 3D 積層造形のきそ,日刊 工業新聞社,(2017).
- (2)小泉雄一郎,千葉晶彦,野村直之,中野貴由:まてりあ,56
 (2017),686-690.
- (3) D. Eyers: Managing 3D printing: Operations Management for Additive Manufacturing, Springer Nature, (2020), 53–55.
- (4) 高橋広幸,井上貴之,中島義雄,横田勝彦,伊藤 学,松垣 あいら,中野貴由:まてりあ,62(2023),58-60.
- (5) B. BlakeyMilner, P. Gradl, G. Snedden, M. Brooks, J. Pitot, E. Lopez, M. Leary, F. Berto and A. du Plessis: Mater. Des., 209 (2021), 110008.
- (6) F. H. Sun, Z. M. Zhang, M. Chen and H. S. Shen: Diam. Relat. Mater., 12(2003), 711–718.
- (7) T. Yamazaki: 18th CIRP Conference on Electro Physical and Chemical Machining (ISEM XVIII), CIRP, vol. 42, (2016).
- (8) "名大など,超硬合金プレス金型作製 リチウム電池部品成 形",2022年3月2日,日刊工業新聞.
- (9) 鈴木飛鳥,伊部博之,高田尚記,小橋 眞,加藤正樹:溶射, 59(2022),210-216.
- (10) 鈴木飛鳥,伊部博之,高田尚記,小橋 眞,加藤正樹:ふえ らむ,27(2022),862-869.
- (11)伊部博之,加藤雄太,山田純也,加藤正樹,鈴木飛鳥,高田尚記,小橋 眞:粉体および粉末冶金,67(2020),313-319.
- (12) H. Ibe, Y. Kato, J. Yamada, M. Kato, A. Suzuki, N. Takata and M. Kobashi: Mater. Des., **210** (2021), 110034.
- (13) A. Suzuki, Y. Shiba, H. Ibe, N. Takata and M. Kobashi: Addit. Manuf., 59 (2022), 103089.
- (14) P. Promoppatum, S.-C. Yao, P. C. Pistorius and A. D. Rollet: Engineering, 3(2017), 685–694.
- (15) D. Rosenthal: Etude theorique du regime thermique pendant la soudre a Tare, Congres national des sciences, 2d., Brussels (1935), 1277–1292.
- (16) D. Rosenthal and R. Schmerber: Weld. J., 17(1938), 2-8.
- (17) D. Rosentha: Weld. J., **20**(1941), 220s–234s.
- (18) D. Rosenthal: Trans. Am. Soc. Mech. Eng., 68(1946), 849– 866.
- (19) T. W. Eager and N. S. Tsai: Weld. J., 62(1983), 346-355.

★★★★★★★★★★★★★★★★★★★★ 2016年9月 名古屋大学大学大学院工学研究科博士

後期課程修了



鈴木飛鳥

2015年4月 日本学術振興会特別研究員(DC1) 2016年10月 日本学術振興会特別研究員(PD) 2017年4月-現職

専門分野:材料プロセッシング,インフォマティクス ◎金属のポーラス化,複合化,積層造形プロセスに従 事.機械学習,データ科学を活用した効率的なプロ セス設計・特性予測を研究.
