

統計的因果推論に基づく小径ダイヤモンドコーティングドリルの

折損予測法の開発

古木 辰也

小径ダイヤモンドコーティングドリルによる硬脆材料への穴あけ加工における工具摩耗や工具異常損耗に起因するドリル折損の抑制は、技術者の目視検査に依存してきた。本研究では、ドリル側面および底面画像を用いて教師あり機械学習により、熟練技術者の感覚的評価を再現するドリル折損確率予測モデルの構築を試みている。令和7年度は、ドリル底面の切りくず目詰り状態の判別および定量化手法を開発した。摩耗やコーティング状態の影響を最小化しつつ、高い判別精度を得られる画像特徴量を特定した。検証の結果、勾配方向ヒストグラム (HoG) および輝度の累積分布関数 (CDFL) が、表面状態の影響を受けずに堅牢な目詰り判別器を構築できることが示された。本手法は効率的な目詰り評価を可能にし、産業現場におけるドリル性能評価へ応用できる。

1. はじめに

製造技術は、石器時代の加工から始まり、産業革命を経て発展してきた。電化によって大量生産を可能とした第二次産業革命、情報技術により効率化が進んだ第三次産業革命を経て、現在は IoT や人工知能を基盤とする「第四次産業革命」の時代であり、柔軟性、カスタマイズ性、高精度化が重視されている。しかし、きさげや金型の手仕上げのように、熟練技能者の経験に依存する工程は依然として存在する。同様に、セラミックス加工に用いられるダイヤモンドコーティングドリルの目詰り評価も、技術者の目視判断に依存している。アルミナや SiC などのセラミックスは、硬さ・化学的安定性・寸法安定性に優れ、半導体製造、医療、光学などで広く用いられている¹⁾。近年では、ウェーハチャックやガスノズルのようにサブミリ径の穴加工が求められ、レーザ加工やダイヤモンドコーティングドリル加工が使用される。図 1(a),(b)は 0.8 mm 径のダイヤモンドコーティングドリルを非接触レーザプローブ (MLP-2, 三鷹光器) で測定した例である。小径ドリルの送り量は 1 μm 未満であり、切れ刃の丸み (約 $R20\ \mu\text{m}$) よりも小さいため、実際の除去は図 1(c)のようにダイヤモンド粒子による研削作用で進む。加工中に発生する粉末状の切りくずが工具に詰まると、抵抗が増加し、加工不良や折損の要因となる。したがって適切な工具状態の監視が不可欠であるが、従来は熟練者の感覚的な判断に頼ってきた。工具状態監視の自動化として、画像処理や機械学習による工具摩耗の推定²⁾や砥石の目詰り評価³⁾などが行われている。しかし、ダイヤモンドコーティングドリル底面の目詰り評価は




図1 ドリル先端画像および底刃稜の断面形状: (a) ダイヤモンドコーティングドリルの SEM 画像, (b) 底刃稜の断面形状, (c) ドリル表面上のダイヤモンド粒子, (d) 摩耗ドリル底面の SEM 写真

複数の要因（逃げ面摩耗、ダイヤモンド粒の不均一性など）により難易度が高い（図 1(d)）．熟練者の洞察をデジタル化する研究⁴⁾もあるが、完全な再現には至っていない．研磨面画像から表面粗さを予測する研究⁵⁾は感覚的評価の再現に近づいているが、計測器による数値に置き換えるアプローチであり、主観的な技能の完全置換ではない．本研究では、ドリル底面の目詰り領域を画像処理で抽出し、技術者による視覚評価を教師データとした機械学習モデルにより、目詰り評価の自動化・定量化を図る．

2. 工作機械搭載型撮像装置によるドリル画像の取得

目詰りを自動評価するため、図 2(a) に示す工作機械搭載型の撮像装置を製作した．この装置には、側面撮影用と底面撮影用の 2 種の光学系を備え、機械上で工具画像を取得できる．図 2(b) は取得した底面画像である．第二逃げ面の大きな摩耗、第三逃げ面の目詰りが確認でき、加工点での切りくず排出が不十分であったことを示す．以前の研究では、目詰りおよびコーティング領域を除去した後逃げ面摩耗を抽出する自動評価手法を提案した⁶⁾．本研究で用いる目詰り評価も、

この装置の底面画像を基礎とする．画像輝度を安定させるため、新品ドリルを基準工具として撮影し、照明条件を調整して画像ヒストグラムを一定に保つよう校正した．




図 2 工作機械搭載型工具撮像システム: (a) 内部構成, (b) ドリル底面画像と逃げ面摩耗領域の抽出例

3. ダイヤモンドコーティングドリル底面における目詰り状態の評価

3.1 画像処理による目詰り面積の測定

図 3(a) の底面画像では、目詰り領域は輝度変化が小さく（低周波成分）、逃げ面摩耗領域は線状の摩耗痕による輝度変化が大きい（高周波成分）．この差に基づき、まず高速フーリエ変換（FFT）を行い、図 3(b) のパワースペクトルから高周波成分（摩耗領域）を抽出し、逆 FFT により図 3(c) の摩耗領域画像を得た．しかし目詰り領域にも微小なノイズが残るため、膨張・収縮、メディアンフィルタ、穴埋め処理などの形態学的処理を組み合わせてノイズを除去した．最後に、元画像から摩耗領域を差し引くことで図 3(d) の目詰り領域が抽出された．この抽出結果の妥当性は電子顕微鏡により確認した．




図 3 目詰り領域抽出処理中に得られたドリル画像: (a) 元画像, (b) 元画像を高速フーリエ変換して得られたパワースペクトル画像, (c) ハイパスフィルタ処理および逆フーリエ変換によって抽出された逃げ面摩耗領域画像, (d) 元画像から逃げ面摩耗領域を除去して得られた目詰り領域画像

3.2 教師あり学習による目詰り度合いの推定

目詰りの度合いは、目詰り領域の面積だけでなく、逃げ面の摩耗量や、ドリル底面に存在するダイヤモンド粒子の分布のばらつきなど、多くの要因によって左右される．そのため、単純に目詰り領域の面積に対して閾値を設けるだけでは、目詰りの程度を適切に判断することは困難である．本研究では、こうした背景を踏まえ、熟練エンジニアが目視で行う目詰り判断を再現するため、教師あり機械学習を用いてその視覚評価技術をデジタル化することを試みた．本研究で用いた機械学習手法はサポートベクターマシン（SVM）である．SVM は、学習データに基づいて複数のクラスを分

離する境界線を定義し、学習に含まれていない未知データに対しても分類を行うことができる。ドリル底面の画像は、摩耗、目詰り、ダイヤモンドコーティング表面の不均一性などによって影響を受けるため、訓練データとして適切な画像特徴量を選定することが、目詰り度合いの正確な推定にとって極めて重要である。ディープラーニング（CNN など）は目詰り評価において高い性能を発揮し得るが、データセットが小さい場合には過学習が生じやすく、モデルの判断根拠が不明確になるというブラックボックス問題がある。そのため本研究では、ドリル底面画像の状態の多様性を適切に説明でき、かつ解釈性が高い特徴量を選別することに重点を置いた。最初に検討した特徴量は、

Histogram of Oriented Gradients（HoG）である。

HoG は画像内の局所的な形状やエッジ方向を特徴量として抽出する手法であり、本研究では画像を 8×8 ピクセル（ $4.7 \mu\text{m} \times 4.7 \mu\text{m}$ ）のセルに分割した。

各セル内における輝度の勾配方向のヒストグラムを計算し、これを特徴量とした。図 4 に示すように、目

詰りが大きい領域では、セル内部の輝度変化が小さいため、得られる特徴量ベクトルは小さくなる。一方、目詰りが小さい領域では輝度変化が大きく、特徴量ベクトルが大きくなる。



図 4 目詰り状態の違いによる HoG 特徴ベクトルの変化:(a) 目詰り領域における輝度変化が小さい場合の特徴ベクトル HoG, (b) 目詰りが軽微な場合に輝度変化が大きくなることで特徴ベクトルが大きくなる様子

次に検討した特徴量は、SIFT（Scale-Invariant Feature Transform）である。SIFT は、まずスケール空間において差分ガウシアン（DoG）を用いて特徴点（キーポイント）を検出し、その周囲の輝度勾配方向のヒストグラムから特徴ベクトルを構築する。本研究では、この特徴点のスケールに着目した。スケールは、特徴点が発見されたときのスケール空間における大きさを表し、画像中の構造物の大きさと密接に関連する。図 5 に示すように、目詰りが大きい画像では特徴点スケールが大きくなり、目詰りが小さい画像では特徴点スケールは小さくなる。この性質を活用し、SIFT キーポイントのスケールを特徴量として採用した。




図 5 目詰りの大小による SIFT キーポイントスケールの違い（円の半径 = キーポイントスケール）:(a) 目詰り量が多い場合の大きなスケール, (b) 目詰りが小さい場合の小さなスケール

最後に、輝度値の累積分布関数（Cumulative Distribution Function of Luminance: CDFL）を特徴量として検討した。加工現場の観察および実験により、目詰り領域は白く、輝度値が約 240 を示し、目詰りのない領域は輝度値が約 80 を示すことが確認された。輝度ヒストグラムを作成すると、目詰りの度合いに応じてピーク位置が変化するが、ダイヤモンドコーティング表面の反射や逃げ面摩耗の影響によって外れ値が生じ、純粋なヒストグラムでは特徴量として安定性が低下する。そのため、本研究では輝度値を昇順に並べた累積分布として扱い、外れ値の影響を抑えた特徴量として利用した。図 6 に示すように、目詰りの小さい画像では低輝度領域に画素が集中し、目詰りが大きい画像では高輝度領域に画素が集中する傾向が明確に現れた。




図 6 目詰りの大小による輝度累積分布関数（CDFL）の違い

これら 3 種類の特徴量を用いて、SVM による目詰り判別器を構築した。訓練データとして、目詰り状態と非目詰り状態の画像をそれぞれ 70 枚ずつ用いた。これらの画像は、エンジニアが底面画像

を目視で評価し、「目詰りあり」または「目詰りなし」のラベルを付けたものである。SVM のカーネル関数の選択も重要である。ドリル底面画像の特徴量は摩耗や目詰り、コーティング状態の不均一性など、多くの要因によって強い非線形性を持つため、RBF (Radial Basis Function) カーネルは高い識別精度を示す可能性がある。しかし、RBF カーネルではカーネルパラメータ γ および正則化パラメータ C の調整が難しく、過学習のリスクや解釈性の低下の問題がある。そこで本研究では、線形カーネルを採用することとし、特徴量の非線形性を抑えつつ単調性を示す特徴量を選択することで、モデルの汎化性能と解釈性の向上を図った。さらに、SVM の汎化性能を最大化するため、k-分割交差検証を用いて C と γ の探索を行い、分類精度、再現率、F 値に基づき最適なパラメータを決定した。探索範囲は 10^{-5} から 10^0 とし、最終的に $C=1$ 、 $\gamma=1$ を得た。初期モデルは二値分類（目詰り／非目詰り）であったが、実際の加工現場では、目詰りがわずかに発生しただけで加工を停止すると加工効率が著しく低下する。そのため、目詰りの程度に応じて継続の可否を判断する必要がある。本研究では、SVM の `predict_proba` によって出力される「確信度」を目詰りの強さを示す指標として使用した。確信度は 0～1 の値として得られ、百分率として表現することで、目詰りがどの程度進行しているかを直感的に理解できるようにした。この確信度は、Platt Scaling により SVM の決定関数の値をロジスティック回帰により確率に変換したものである。

4. 実験結果

本研究で構築した SVM 判別器に対して、未知のドリル底面画像を入力し、各ドリルの目詰り確信度を評価した。未知データとして使用したドリル底面画像を図 7 に示す。この図に示されるように、目詰り領域の大きさ（前節 3.1 で述べた目詰り面積）はドリルによって大きく異なり、非常に大きいものからほとんど目詰りが見られないものまで幅広く存在した。また、逃げ面の摩耗の大きさについても同様に幅があり、加工現場や実験条件に応じてさまざまな状態の画像が含まれていた。さらに、ドリル中心部の欠損など、加工現場で実際に遭遇しうる特異な状態の画像もあわせて評価に使用した。図 8 は、目詰り面積と SVM 判別器から得られた目詰り確信度との関係を示したものである。この図に示す曲線は、実験結果に対して指数関数的減衰モデルを用いてフィッティングしたものである。図から分かるように、全ての特徴量において目詰り面積と確信度の関係が線形となるわけではなく、HoG 特徴量のみが目詰り面積に対して単調増加の傾向を示した。一方で、SIFT の特徴点スケールおよび CDFL は、目詰りが小さい範囲において確信度のばらつきが大きく、非線形性が顕著に現れた。目詰り面積と確信度に対して指数関数的減衰モデルを適用した回帰分析により算出された決定係数 R^2 は、HoG 特徴量では $R^2=0.95$ 、SIFT の特徴点スケールでは $R^2=0.29$ 、CDFL では $R^2=0.84$ であった。また、目詰り面積と確信度の順位相関を表す Spearman の相関係数 ρ を算出したところ、HoG は $\rho=0.87$ 、SIFT は $\rho=0.39$ 、CDFL は $\rho=0.84$ となった。これらの結果から、HoG 特徴量はさまざまな状態のドリル底面画像に対して有効であり、目詰り面積に応じて安定した傾向を示すことが確認された。ここで留意すべき点として、学習データおよび検証データとして使用したドリル底面画像には、目詰り領域だけでなく、逃げ面の摩耗領域も写り込んでいることが挙げられる。この摩耗領域の存在が、特徴量の性能に影響を与え、それぞれの特徴量が本来有する識別能力を十分に発揮できなかった可能性がある。例えば、SIFT の特徴点スケールは、特徴点から輝度変化の大きい箇所までの距離に相当するが、今回の実験では特徴点の検出数が少なく、検出数を 10 点としていた。特徴点数が少ないことにより、スケール値が画像全体を十分に反映できず、目詰

りの大小を安定して表現できなかつたと考えられる．また，CDFL は輝度値の累積分布であるため，逃げ面の摩耗部分のように高輝度領域が存在すると，その影響を受けて高輝度帯の累積頻度が増加してしまう．その結果，目詰りが小さい場合であっても高輝度の画素数が増え，目詰り評価の解釈性を損なう可能性があつた．一方で HoG は，画像全体の輝度の勾配情報を用いて特徴量を構成するため，線状摩耗痕を持つ規則的な摩耗領域と，不規則なコーティング表面，さらに平坦な目詰り領域などを区別することが可能であり，これが高い推定精度につながつたものと考えられる．




図 7 SVM 判別器に与えた推定精度検証用ドリル底面画像 (AI : 目詰り面積) : (a) $AI=0.00 \text{ mm}^2$, (b) $AI=7.07 \times 10^{-4} \text{ mm}^2$, (c) $AI=1.36 \times 10^{-3} \text{ mm}^2$, (d) $AI=5.39 \times 10^{-3} \text{ mm}^2$, (e) $AI=3.86 \times 10^{-2} \text{ mm}^2$, (f) $AI=8.88 \times 10^{-2} \text{ mm}^2$, (g) $AI=0.136 \text{ mm}^2$, (h) $AI=0.197 \text{ mm}^2$




図 8 目詰り面積と目詰り確信度の関係

以上のように，ドリル底面画像に逃げ面摩耗部を含むことで推定精度の低下を招いたと考えたため，底面画像から逃げ面摩耗部を除去した画像を作成し，判別モデルの再構築および再検証を行った．ドリル底面画像から逃げ面摩耗領域を取り除いた状態で再び SVM 判別器を構築した結果を図 9 に示す．これに対応する再検証の結果を図 10 に示す．逃げ面摩耗領域を除去して特徴量を再計算したところ，指数関数的減衰モデルを用いた回帰分析により得られた決定係数 R^2 は，HoG 特徴量で $R^2=0.92$ ，SIFT の特徴点スケールで $R^2=0.46$ ，CDFL で $R^2=0.97$ となり，いずれも逃げ面摩耗領域を含んだ場合よりも改善が見られた．Spearman の相関係数 ρ' については，HoG で $\rho'=0.82$ ，SIFT で $\rho'=0.62$ ，CDFL で $\rho'=0.95$ となった．HoG 特徴量では推定精度がわずかに低下したものの，概ね安定した挙動を維持していた．CDFL は，逃げ面摩耗に起因する高輝度領域が特徴量から取り除かれたことにより，目詰り面積に対して単調な増加傾向を示すようになり，特徴量の解釈性が大きく向上した．一方，SIFT の特徴点スケールは，特徴点数が十分に得られなかったことから改善幅が限られた．特徴点数を増やすことで性能向上が期待されるが，その場合，計算コストの増大や過学習の発生が懸念される．目詰りの有無を判断する二値分類における識別精度は，HoG が 94%，SIFT が 67%，CDFL が 100%であった．これらの結果より，CDFL は目詰りの推定精度および特徴量としての解釈性の点で，非常に優れた特徴量であることが確認された．




図 9 逃げ面摩耗領域を除去したドリル底面画像の例




図 10 ドリル底面画像から逃げ面摩耗領域を除去した場合の目詰り面積と信頼度の関係

5. おわりに

本研究では、ダイヤモンドコーティングドリルの底面に生じる目詰りの程度を支持ベクターマシン (SVM) を用いて推定するために、目詰りのない領域の影響を最小化しつつ高い推定精度を維持できる画像特徴量を特定することを目的とした。検証の結果、HoG 特徴量および CDFL 特徴量は目詰りの大きさと明確かつ一貫した関係を示すことが明らかとなり、表面状態が一定でない場合においても堅牢な目詰り判別器を構築する上で極めて有効であることが確認された。これにより、従来は熟練者の視覚判断に依存していた目詰り評価のデジタル化が可能となった。また、本研究で用いた工具撮像装置は、ドリル底面における目詰りだけでなく、先端角の変化などドリルの摩耗状態も計測できるため、工具の総合的な状態監視への応用が期待される。今後の研究では、目詰り条件と他の摩耗特性をあわせて分析することで、ドリル折損の発生確率を推定する破損予防システムの開発に取り組む必要がある。

参考文献

- 1) Jia X, Chen Y, Liu L, Wang C, Duan J (2022) Advances in Laser Drilling of Structural Ceramics. *nanomaterials* 12(2):230.
- 2) Friedrich M, Gerber T, Dumler J, Döpper F (2023) A system for automated tool wear monitoring and classification using computer vision. *Procedia CIRP* 118:425-430.
- 3) Vipin G, K. Leo Dev Wins (2016) Quantitative Analysis of Grinding Wheel Loading Using Image Processing. *Procedia Technology* 25:885-891.
- 4) Bales L G, Das J, Tsugawa J, Linke B, Kong Z (2017) Digitalization of Human Operations in the Age of Cyber Manufacturing: Sensorimotor Analysis of Manual Grinding Performance. *Journal of Manufacturing Science and Engineering* 139(10):101011.
- 5) Furuki T, Iriguchi H, Kousaka H (2023) Development of surface roughness prediction method based on polished surface image using supervised learning. *Journal of the Japan Society for Abrasive Technology* 67(1):30-35.
- 6) Furuki T, Nagai T, Nishigaki K, Suda T, Kousaka H (2024) In Situ Evaluation of Drill Wear Using Tool Image Captured on Machining Center. *International Journal of Automation Technology* 18(2):181-188.
- 7) Shokrani A, Dogan H, Burian D, Nwabueze D T, Kolar P, Liao Z, Sadek A, Teti R, Wang P, Pavel R, Schmitz T (2024) Sensors for in-process and on-machine monitoring of machining operations. *CIRP Journal of Manufacturing Science and Technology* 51:263-292.
- 8) Dalal N, Triggs B (2005) Histograms of oriented gradients for human detection. 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition:886-893.
- 9) Lowe D G (2004) Distinctive Image Features from Scale-Invariant Keypoints. *International Journal of Computer Vision* 60:91-110.