

# CNC工作機械による金属材料切削加工時のFCDDモデルを用いた異常検知

高田・永田研究室 EDM2510 森本 智明

## 背景と目的

コンピュータ数値制御(CNC)の工作機械を用いた長時間に及ぶ大型被削材の切削加工や、複雑な形状を有する特殊加工などを行う必要がある製造業においては、工作機械の動作異常における加工品質の不揃いによる歩留まりの低下、生産ラインのストップなどが問題となることが多い。従来は専門のNCオペレータが常時、工作機械の操作と、加工中の異常監視を行っていたが、長時間の加工の場合には特に大きな負担となっている。

本研究では、稼働している工作機械装置本体と、切削工具や加工対象である被削材の異常監視と異常予測が可能なシステムを検討している。時間領域の音データに基づく工作機械による切削加工時の異常検知と、コンカレントな異常時間領域の可視化の機能を実現するためにFCDD (Fully Convolutional Data Description) モデルの適用を試みる。異常検知を目的とするFCDDは本来、正常及び異常の画像データをもとに訓練されるモデルであるため、行ベクトルとして抽出した生の時系列データを正規化した後に行方向に列ねることでマップ化する方法を採用する。これにより、時系列データであっても簡単にFCDDモデルの訓練に利用できるようになったので報告する。

## 提案するSBデータベースのFCDDモデル

FCDDモデルは、入力画像 $X$ から $u \cdot v$ サイズに縮小された特徴マップ $\phi(X; W)$ を生成するため、この特徴マップに基づいて欠陥領域のヒートマップを生成することができる。特徴マップのpseudo-Huber損失は次式の $A(X)$ で与えられ、ヒートマップを出力できるようにピクセルごとに行われる。

$$A(X) = \sqrt{\phi(X; W)^2 + 1} - 1$$

また、FCDDモデルを訓練するための目的関数は次式で与えられる。

$$\min_W \frac{1}{n} \sum_{i=1}^n (1 - y_i) \frac{1}{u \cdot v} \|A(X_i)\|_1 - y_i \log \left( 1 - \exp \left( -\frac{1}{u \cdot v} \|A(X_i)\|_1 \right) \right)$$

ここで、第1項は学習画像が良品の場合、すなわち $y_i = 0$ の場合に有効な値を持ち、L1ノルム $\|A(X_i)\|_1$ を特徴マップの全画素数 $u \cdot v$ で割った値である。この値は1画素当たりの平均値と見なすことができる。したがって、学習において良品の画像をネットワークに与えた場合、ヒートマップを形成する各画素が0に近づくように重みが調整される。

第2項は学習画像のラベルが不良品の場合、すなわち $y_i = 1$ の場合に有効となり、1画素当たりの平均損失が大きくなるにつれて $\exp(\cdot)$ が0に近い値となるため、対数関数 $\log(\cdot)$ の値も学習時間の経過とともに0に近づく。

pseudo-Huber損失関数を含む目的関数により、欠陥のない画像の平均画素値の和は最小化され(より原点の近くへマッピングされる)、欠陥を含む画像の平均画素値の和は最大化される(より原点から遠くへマッピングされる)ことが考察できる。図1には本研究で提案する「時系列データに対応できるFCDDモデル」のネットワーク構造を示す。

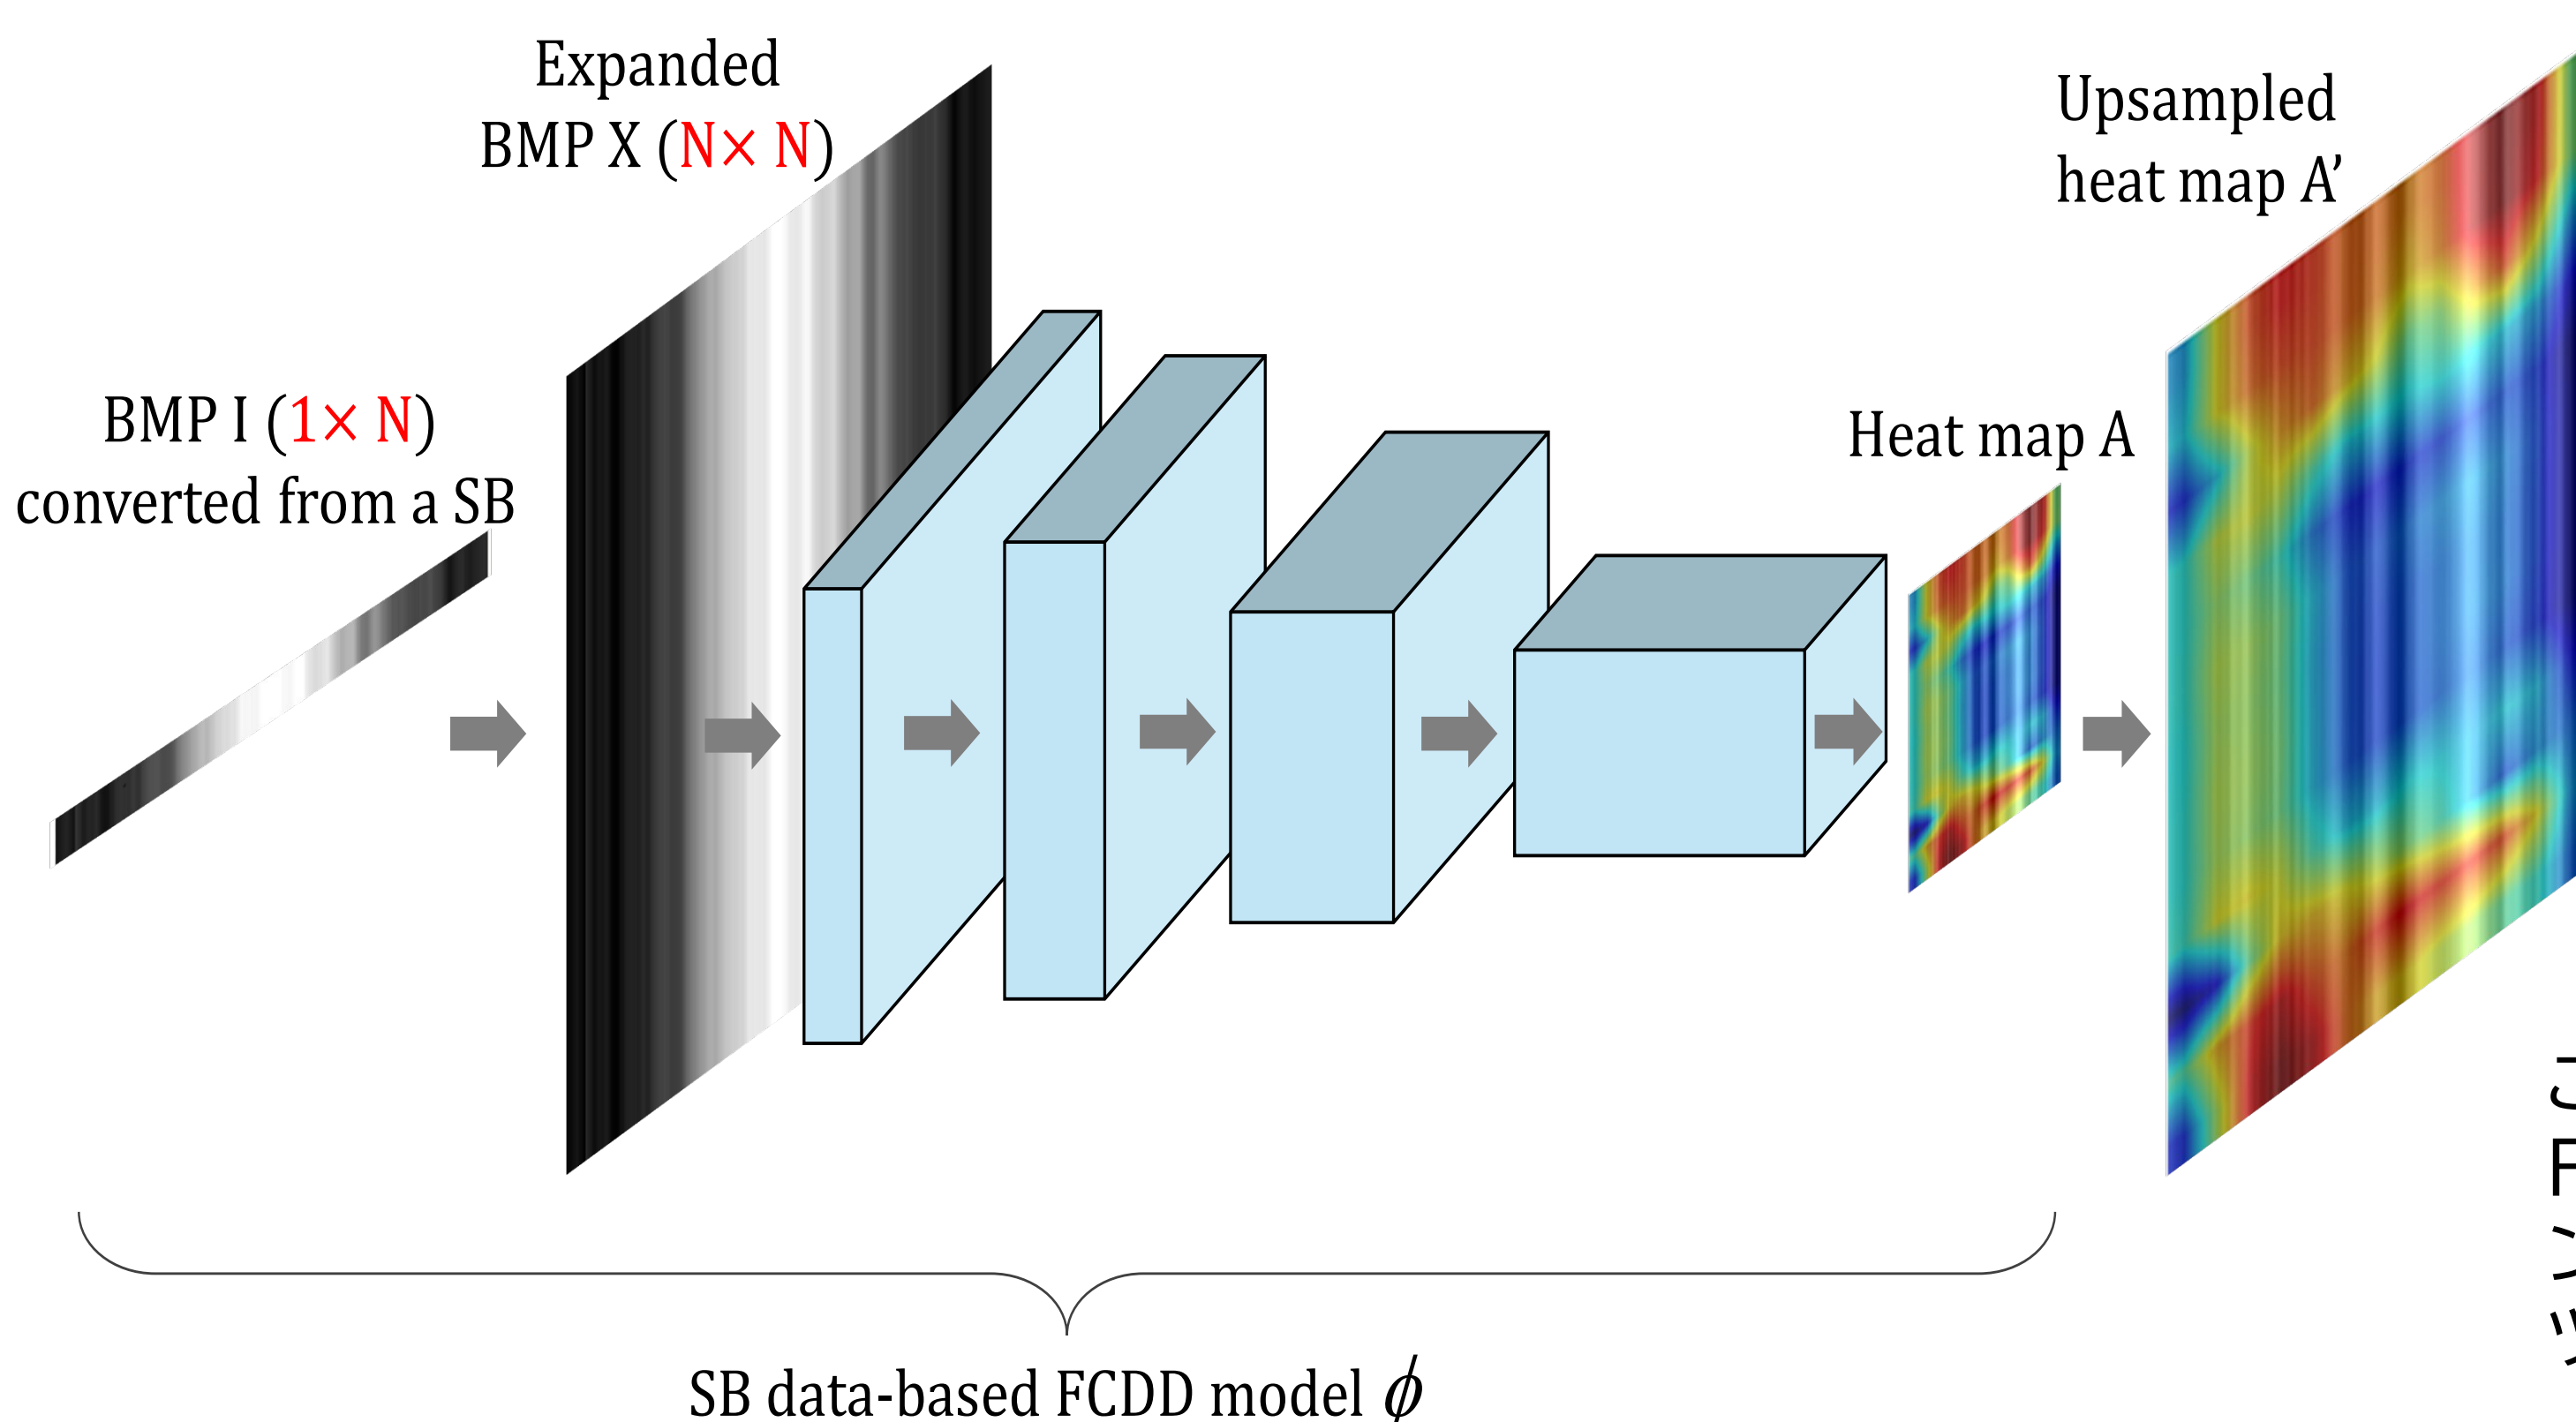


Fig. 1 Proposed SB data-based FCDD model for time-series data.

## FCDDモデルの訓練と閾値の設定

図2に示すNCフライス盤が加工時に発するサウンドブロック(SB)データを用いてFCDDモデルを訓練し、正常音と異常音の識別実験を行うことで汎化性能を評価した。使用した工具には、図3(a)の正常エンドミルと図3(b)の一部が欠けたエンドミルを用意し、表1のように正常加工時と異常加工時の2種類の訓練用とテスト用のSB データを収集した。表1の訓練データを用いて100エポックの訓練終了後にFCDDモデルを得た。このとき、全訓練データに対するFCDDが出力する異常スコアを図4に示しているが、正常音スコアと異常音スコアの分布状況より、中間付近の1.3をテスト用SBデータを識別するための閾値として設定した。なお、異常スコアは次式で与えられるFCDDの出力マップのピクセル値の平均値である。この値が大きいほど、異常度が高いSBデータであることが予測できる。

$$\text{Mean Anomaly Score} = \frac{1}{u \cdot v} \|A(X_i)\|_1$$



Fig. 2 CNC milling machine.




Fig. 3 Examples of end mills.

Table 1 Labels and number of sound blocks for training and testing an FCDD model.

Label	Machine Tool	Training	Test
Normal	NC Milling Machine	50	100
Anomaly	NC Milling Machine	50	100

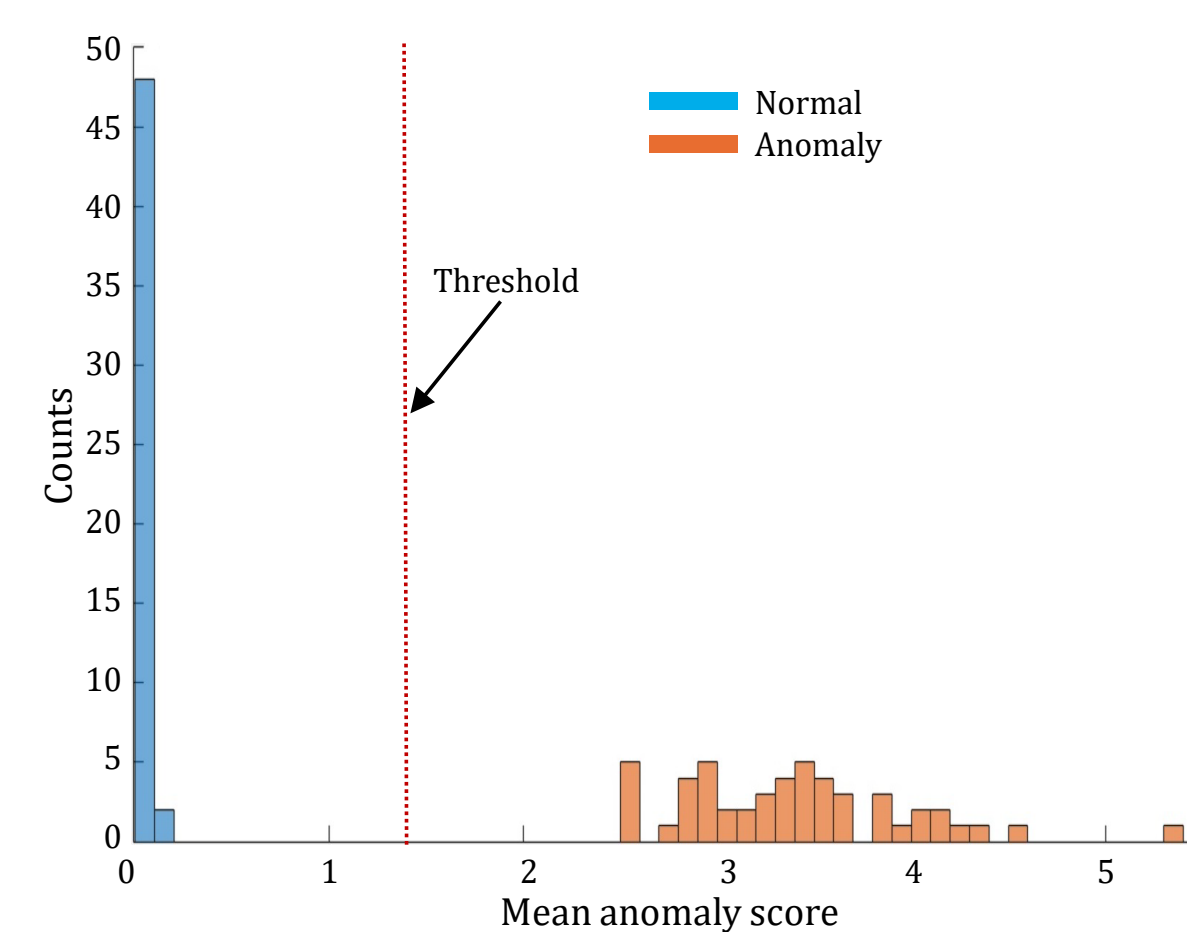


Fig. 3 Scores of training SB data.

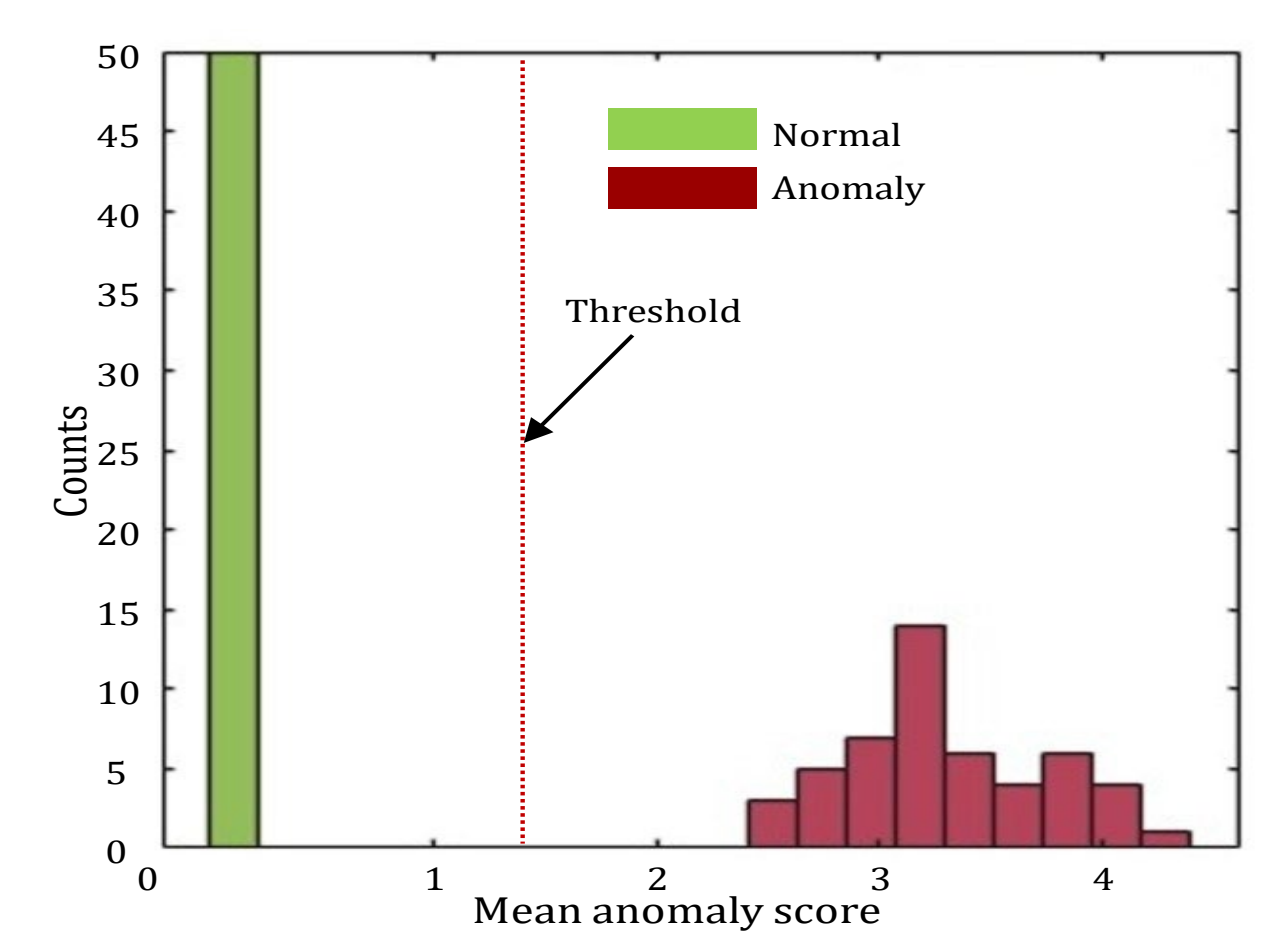


Fig. 4 Scores of test SB data.

## テスト用SBデータを用いたFCDDの評価

表1のテスト用SB データを用いて訓練後のFCDDの汎化性能を評価した結果、表2のように全SBデータを良好に識別することができた。図4には、このときFCDDによって判定されたテスト用SB データの平均異常度スコアのヒストグラムを表示している。また、図5には、正常音と異常音のSBデータの可視化結果を示している。

Table 2 Classification results of test SB data for the FCDD model.

Predicted \ True	Predicted	
	Anomaly (NG)	Normal (OK)
Anomaly (NG)	100	0
Normal (OK)	0	100

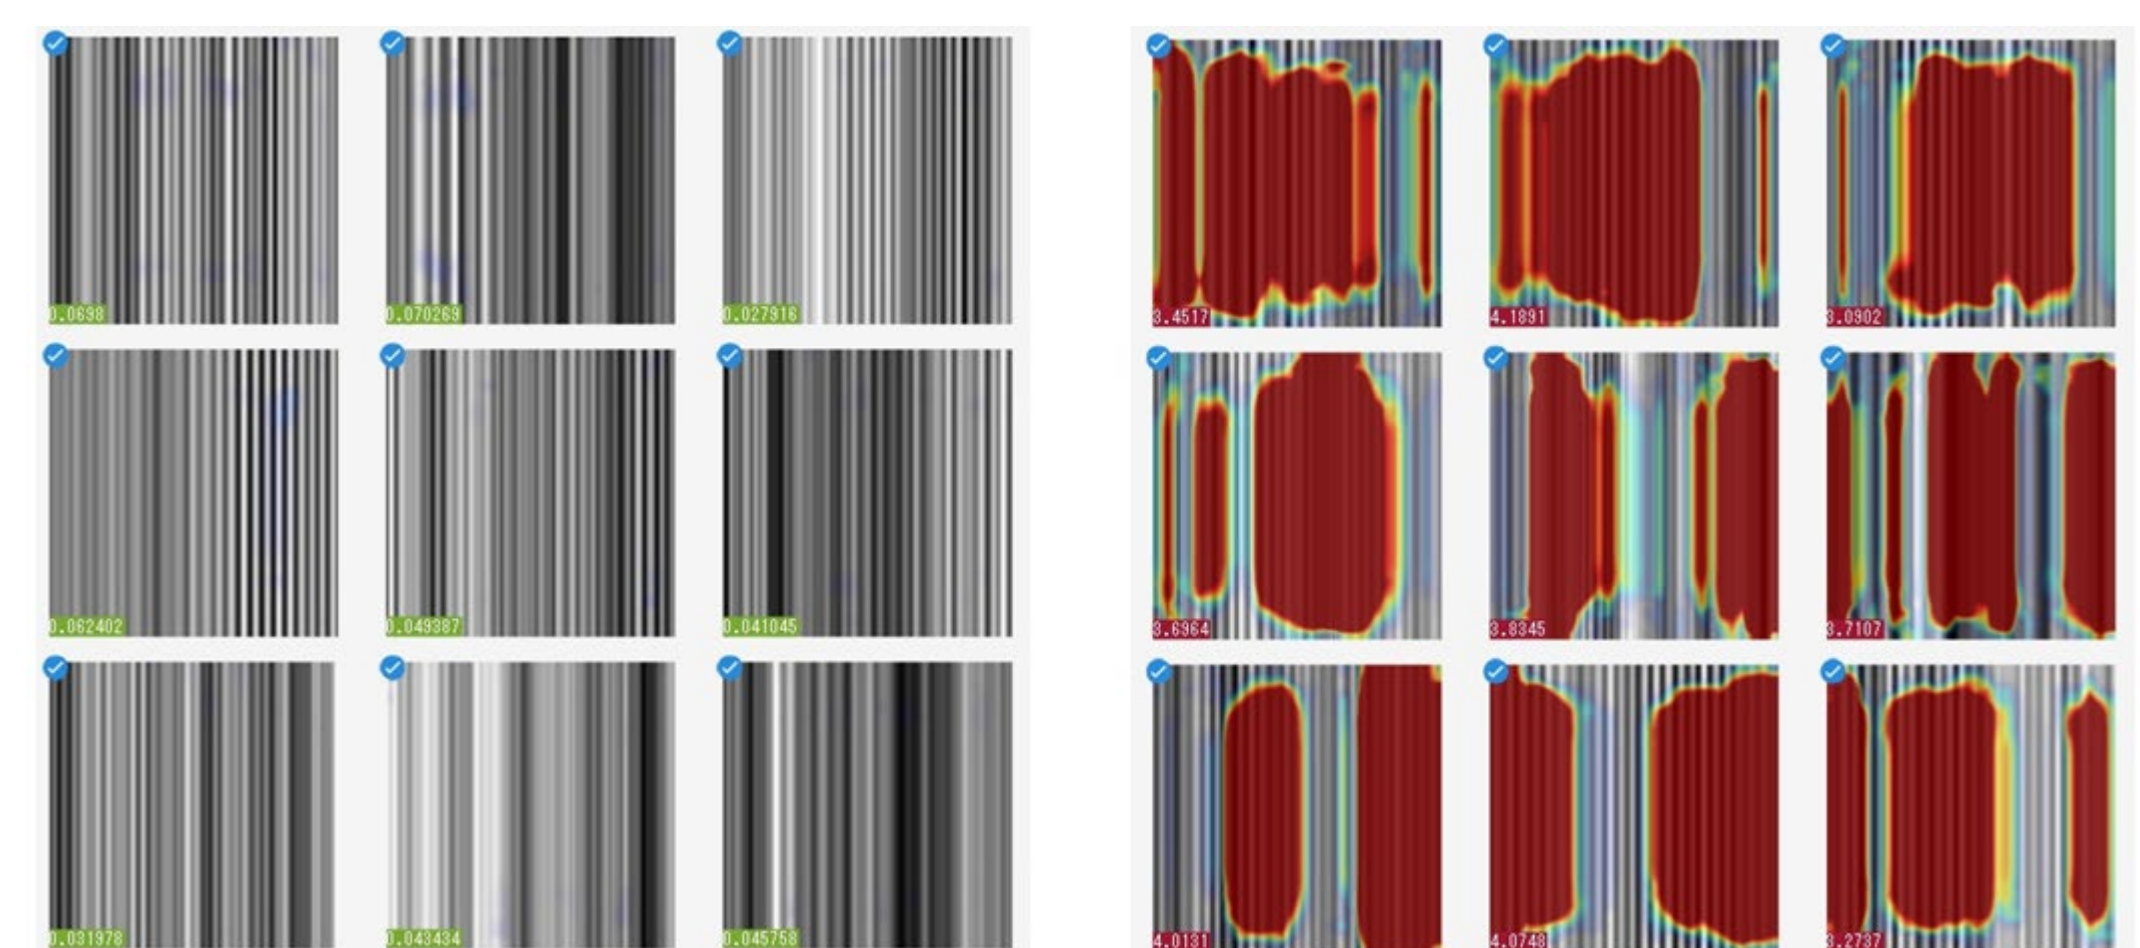


Fig. 5 Visualization results of normal and anomalous regions in test SB data.

## まとめと今後の展開

行ベクトルとして抽出した生の時系列データを正規化した後に行方向に列ねることでマップ化する方法を採用した。これにより、時系列データであっても簡単にFCDDモデルの訓練に利用できるようになり、FCDDによる異常検知とコンカレントな時間領域での可視化、すなわち、異常箇所をGrad-Cam等の別ステージのツールを使用せず直接可視化をする事が可能になった。

今後は、エンドミルを1回使用したもの、2回使用したものから複数回加工したものなど多数の加工音を採取し、性能評価とモデルの改善を行う予定である。