

機械学習を用いた エマルション検出器中の飛跡認識



吉田純也^{a,b}, Abdul Muneem^{a,c}, 梅本篤宏^d, 江川弘行^a, 笠置歩^{a,e}, 齋藤武彦^{a,f,g},
齋藤奈美^a, 瀧雅人^h, 中川真菜美^a, 長縄直崇^d, 日野正裕ⁱ, 広田克也^d, 武藤直人^d

^a High Energy Nuclear Physics Laboratory, RIKEN

^b Department of Physics, Tohoku University

^c Ghulam Ishaq Khan Institute of Engineering Sciences and Technology, Pakistan

^d Department of Physics, Nagoya University

^e Graduate School of Engineering, Gifu University

^f GSI Helmholtz Centre for Heavy Ion Research, Germany

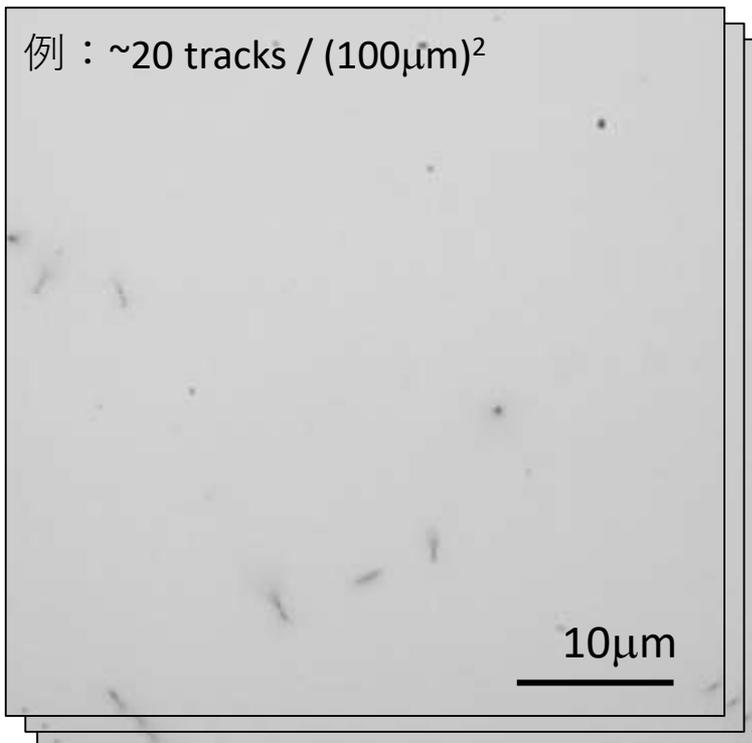
^g School of Nuclear Science and Technology, Lanzhou University, China

^h Graduate School of Artificial Intelligence and Science, Rikkyo University

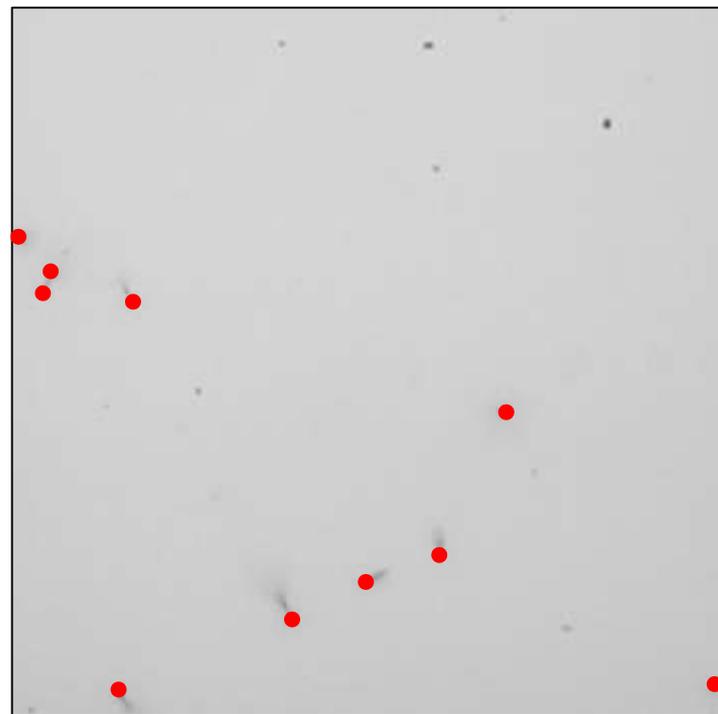
ⁱ Institute for Integrated Radiation and Nuclear Science, Kyoto University

理研グループの開発：

微粒子エマルジョンNIT（Nano Imaging Tracker）の、
中性子イメージングに向けた飛跡検出



Input: 顕微鏡断層画像のセット



Output: 個々の飛跡の付け根の位置座標

当面の目標：

$(100\mu\text{m})^2$ あたり 10^4 本の本数密度（統計誤差1%）での飛跡認識

KUR CN-3にて、画像処理開発に用いるサンプルを作成した。

飛跡本数密度と見え方の予想

[tracks / (100 μ m)²]

1×10^2

3×10^2

1×10^3

3×10^3

1×10^4

シミュレーション画像



目標とする飛跡密度

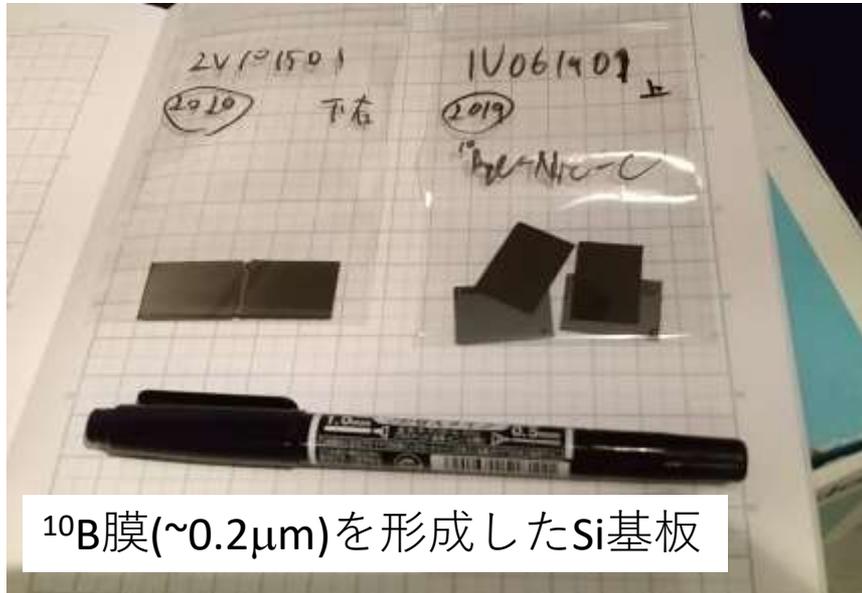
KUR CN-3での実験

2020年10月：照射時間と飛跡本数密度の対応を測定。

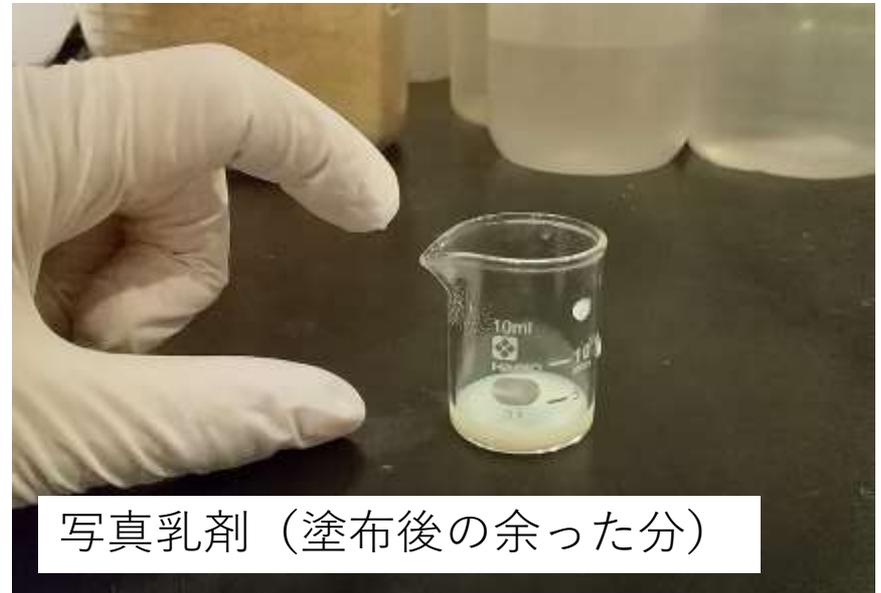
~ 10^2 tracks, ~ 10^3 tracks / (100 μ m)² のサンプルを作成。

2020年12月： 1×10^4 tracks / (100 μ m)² のサンプルを作成。

エマルション検出器



^{10}B 膜($\sim 0.2\mu\text{m}$)を形成したSi基板



写真乳剤 (塗布後の余った分)



遮光シートにパックした検出器



KUR CN-3

照射時間と飛跡本数



2020年10月の照射サンプルを
現像後に目視で実測：

照射時間	tracks / (100 μ m) ²
1000 sec	390 +- 16

10^6 n/cm²/s @ 1MWを仮定

¹⁰B膜の検出効率:

$$390 / (10^6 \text{ n/cm}^2/\text{s} * 1000 \text{ s} * 10^{-4} \text{ cm}^2) \sim 0.4\%$$

2020年12月の照射実験

照射時間	tracks / (100 μ m) ²
10000 sec	(3.90 +- 0.16) * 10 ³
25000 sec	(0.98 +- 0.04) * 10 ⁴
26250 sec	↑ x 1.05

画像の比較

[tracks / (100 μ m)²]

$1 \cdot 10^2$

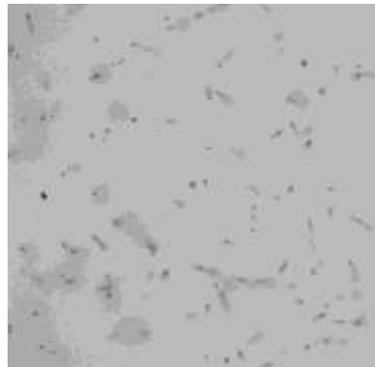
$3 \cdot 10^2$

$1 \cdot 10^3$

$3 \cdot 10^3$

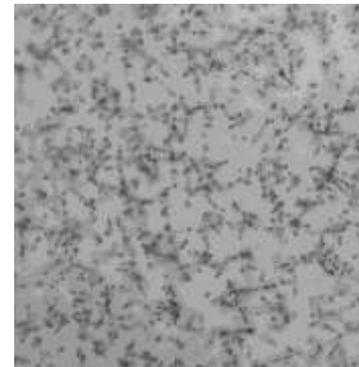
$1 \cdot 10^4$

シミュレーション画像



$\sim 4 \cdot 10^2$ tracks / (100 μ m)²

11/12
撮像@名大



$\sim 4 \cdot 10^3$ tracks / (100 μ m)²

2021年1月中旬に
撮像予定。

機械学習による飛跡検出

[tracks / (100 μ m)²]

1×10^2

3×10^2

1×10^3

3×10^3

1×10^4

シミュレーション画像

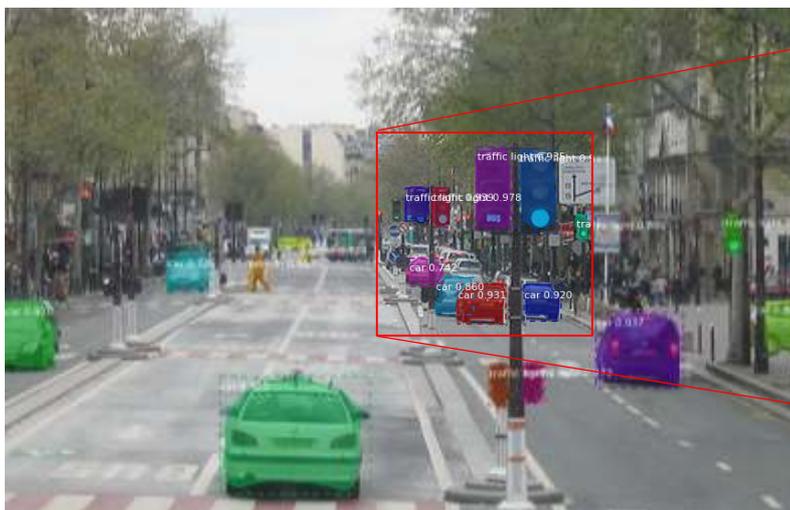


従来の画像処理による検出

機械学習の導入

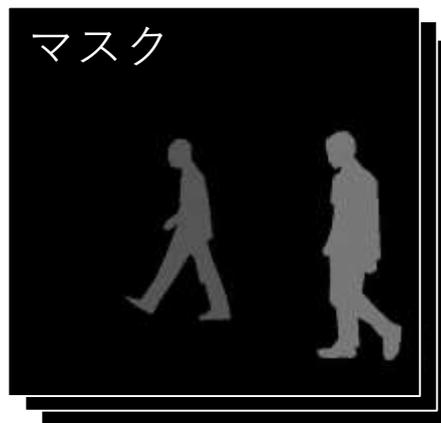
- 密集した飛跡の認識。
- 様々な画質、飛跡本数密度を包括する手法を目指す。

機械学習 (Mask R-CNN*) を用いた物体検出



https://github.com/matterport/Mask_RCNN

例)
歩行者データセット” Pennsylvania-Fudan dataset ”



- 画像中から目的の物体を検出
- カテゴリ分類のスコア
- 混み合った部分からの検出

• 原子核物理の実験に活用中
J. Yoshida et al., N.I.M-A, 989 (2021) 164930

教師データ

- 画像とマスクのペア
- 大量に必要 (10^4 枚以上)

→シミュレーションを活用し、
入力画像-マスク対を大量に生成

*) Region Based Convolutional Neural Networks

ロードマップ

Step 1. 機械学習を用いて飛跡検出が可能か？

飛跡密度 $< 10^2$ tracks / $(100\mu\text{m})^2$

シミュレーション画像で学習、実際の画像で認識

Step 2. 飛跡の根本検出は可能か？

飛跡密度 $\sim 10^3$ tracks / $(100\mu\text{m})^2$

シミュレーション画像で学習、シミュレーション画像で認識

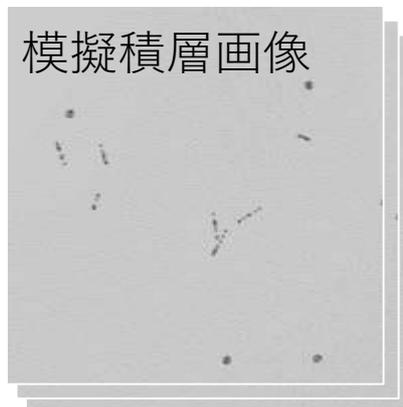
Step 3. 実際の高密度飛跡画像でどこまで検出可能か？

飛跡密度 $10^3 \sim 10^4$ tracks / $(100\mu\text{m})^2$

シミュレーション画像で学習、実際の画像で認識

Step 1: 原理実証

シミュレーション (教師画像)



模擬積層画像

~20 tracks / (100 μ m)²
正解にのみマスク



マスク

学習

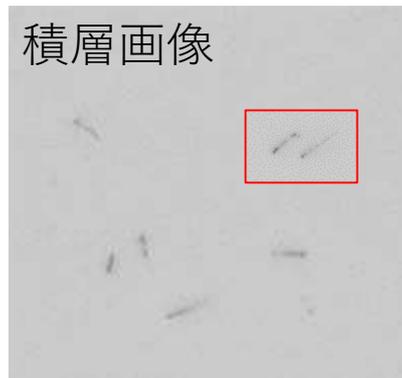
Mask R-CNN

- ・ 飛跡を検出
- ・ ノイズを無視

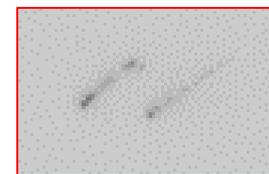
入力



実際の画像



積層画像



出力



検出結果

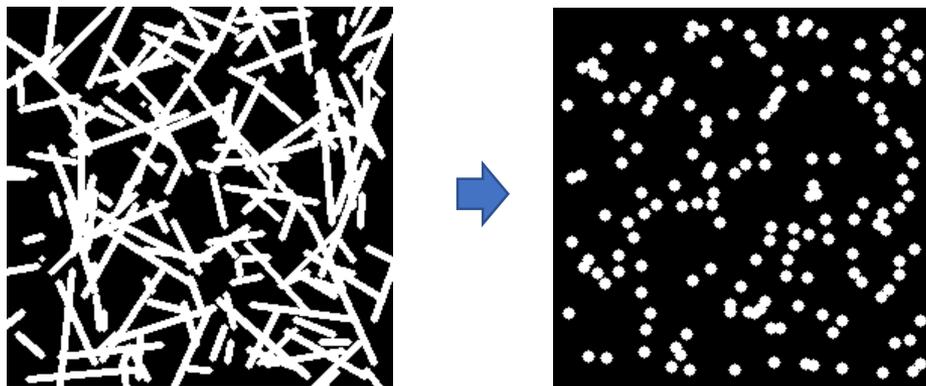


目視結果と比較: 検出効率 98.5%, ノイズ誤検出 2.4%

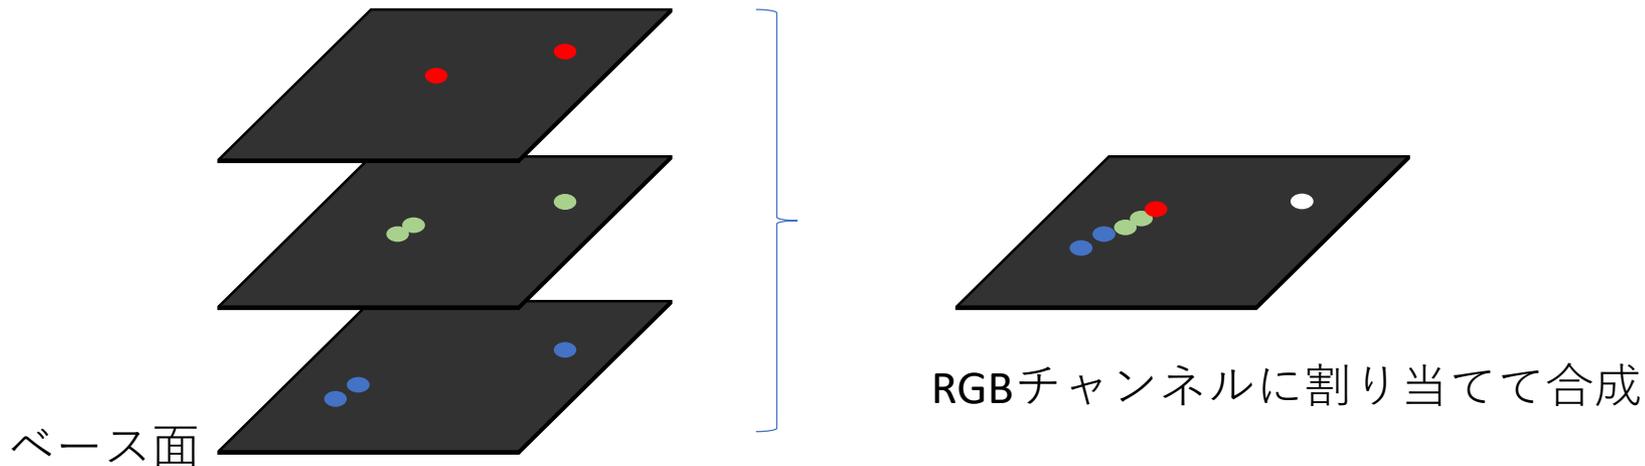
シミュレーション + 機械学習の原理を実証。 → Step2へ。

Step 2:高密度飛跡の根本認識のために

1. 根本の位置のみに丸印、マスクの面積を小さく。



2. 異なる深さの画像を色で区別。

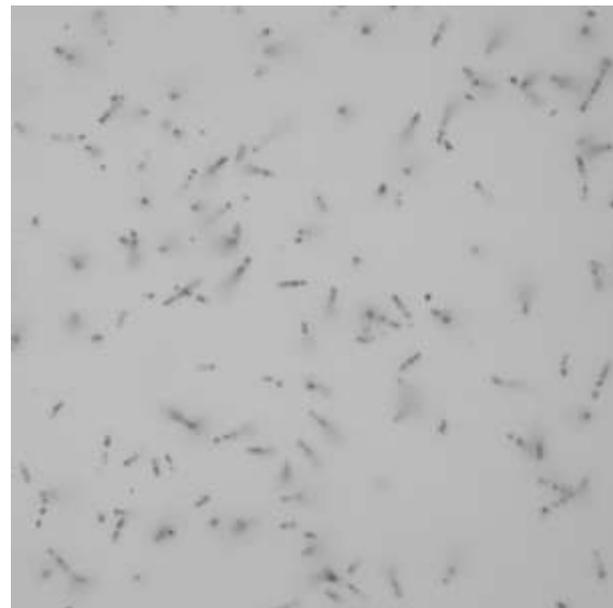


画像シミュレータの現状

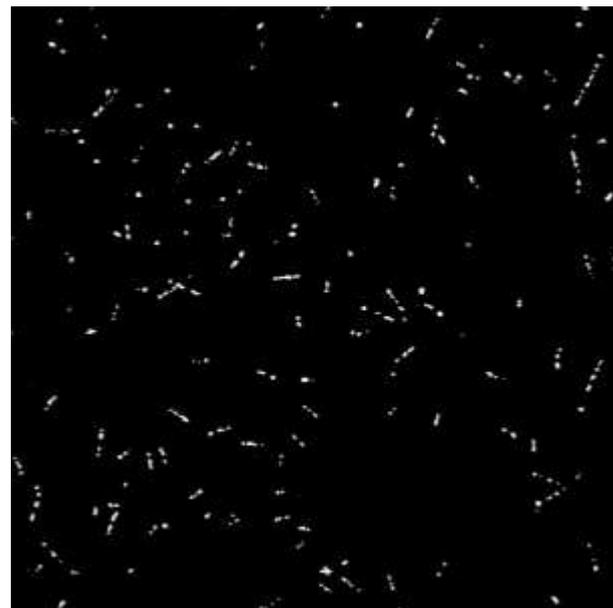
Simulated image

Real image

顕微鏡像

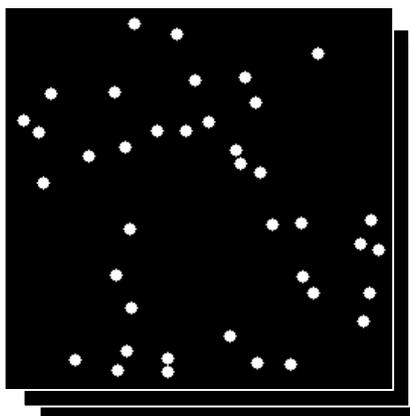
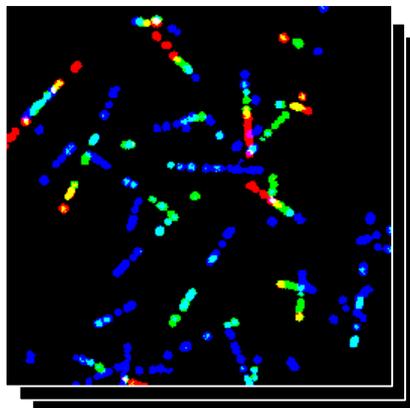


二値化画像



Step 2: 飛跡の根本検出

シミュレーション画像 (教師画像)



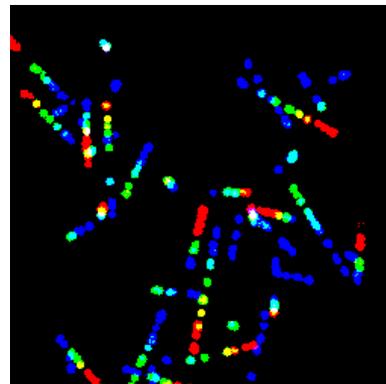
学習

Mask R-CNN

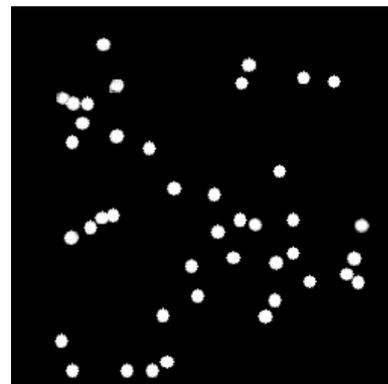
入力



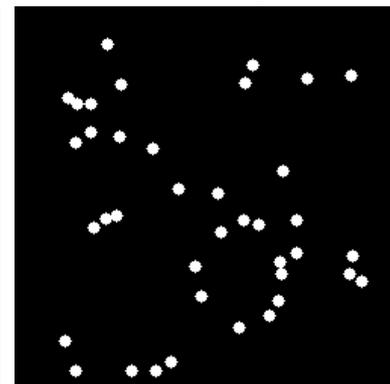
シミュレーション画像 (検証用)



出力



正解



- $2 \cdot 10^3$ tracks / $(100\mu\text{m})^2$ 相当
- 画像1000組で学習
- $256 \text{ pixels} * 256 \text{ pixels} = (14.1\mu\text{m})^2$

おおむね一致。
検出効率、S/N比の定量評価中。
Step2の開発を進行中。

まとめ

- 微粒子エマルジョン検出器の中性子イメージングへの応用
- 当面の目標：飛跡本数密度 $10^4 \text{ tracks} / (100\mu\text{m})^2$ で飛跡認識
- KURでの照射実験で、 $\sim 4 \cdot 10^2$, $\sim 4 \cdot 10^3$, $\sim 1 \cdot 10^4 \text{ tracks} / (100\mu\text{m})^2$ のサンプルを作成した。
- 機械学習を用いた飛跡認識を開発中。
教師画像はシミュレーションを活用。
飛跡本数密度は数千 $\text{tracks} / (100\mu\text{m})^2$ までは適応可能か。

今後

- $10^4 \text{ tracks} / (100\mu\text{m})^2$ のサンプルの撮像 @ 名古屋大顕微鏡
- 画像シミュレータを改良し、実データでの飛跡認識に適応
- 飛跡認識率の飛跡密度依存性を評価