

jh220044

機械学習ソフトウェアへの ソフトウェア自動チューニング技術の適用

田中輝雄	工学院大学 情報学部 (代表者)
大島聡史	名古屋大学 情報基盤センター (副代表者)
藤井昭宏	工学院大学 情報学部
加藤由花	東京女子大学 現代教養学部
藤家空太郎	工学院大学 大学院情報学専攻
ヨウケン	工学院大学 大学院情報学専攻

共同研究体制

氏名	所属機関・部局名	役割・担当分野等
田中 輝雄	工学院大学・情報学部	研究総括 自動チューニング手法
大島 聡史	名古屋大学・情報基盤センタ	GPU・メモリア向け アルゴリズム
藤井 昭宏	工学院大学・情報学部	並列数値計算アルゴリズム
加藤 由花	東京女子大学・現代教養学部	機械学習プログラム ・データ提供
藤家 空太郎	工学院大学・大学院情報学専攻	自動チューニング ソフトウェア開発, 評価
ヨウ ケン	工学院大学・大学院情報学専攻	自動チューニング ソフトウェア開発, 評価

背景と目的

- 自動チューニング(AT)におけるソフトウェアの性能を決定する性能パラメタ最適組合せ探索の研究を推進
 - 機械学習プログラムの学習モデルのハイパーパラメタ選択に, このATを適用
 - 対象アプリケーションは,
 - (1) 「人を回避しながら動くロボットの制御」に向けた人移動予測AI
(歩行者経路予測アプリ)
 - (2) 超解像 (低解像度画像を高解像度画像に変換) を機械学習で実現 ⇒ 今回, 報告
 - 機械学習では,
 - (1) 大量のデータを扱い膨大な学習時間を要する
 - (2) さらにデータ選択により結果が一意に定まらない
- 【目的 1】 スーパーコンの高性能環境の有効利用, ならびに機械学習方法への適用の工夫により, ハイパーパラメタ探索時間を大幅に削減 ⇒ 今回, 報告
- 【目的 2】 機械学習で生じる揺らぎを評価し, 推定パラメタの組合せの安定性を確保

超解像の機械学習プログラム

- 超解像とは、低解像度画像を高解像度画像に変換する技術
- 対象プログラム:Dense Deep Back-Projection Networks(D-DBPN) *1)
 - ▶ 豊田工業大学の浮田教授グループが開発
 - ▶ 低解像度画像の各辺を2倍, 4倍, 8倍の高解像度画像に拡大
 - 本研究では4倍への拡大
 - ▶ 画像の画質をPerceptual Score*2) で評価
 - 小さいほど性能が良い
 - 人が見て綺麗かどうかの指標
 - MATLAB でPIRM (Perceptual Image Restoration and Manipulation)プログラムを実行して性能評価値を計算

*1) M. Haris, G. Shakhnarovich, N. Ukita, "Deep Back-Projection Networks for Super-Resolution," 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (2018)

*2) Y. Blau, R. Mechrez, R. Timofte, T. Michaeli, L. Zelnik-Manor, "The 2018 PIRM challenge on perceptual image super-resolution," Proceedings of the European Conference on Computer Vision (ECCV) (2018)

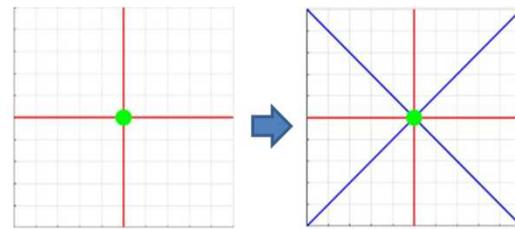
超解像プログラム(ハイパーパラメタ)の設定

- 今回の超解像プログラムでATを適用するハイパーパラメタを以下に提示
- 組み合わせ13,310(= $10 \times 11 \times 11 \times 11$)通り

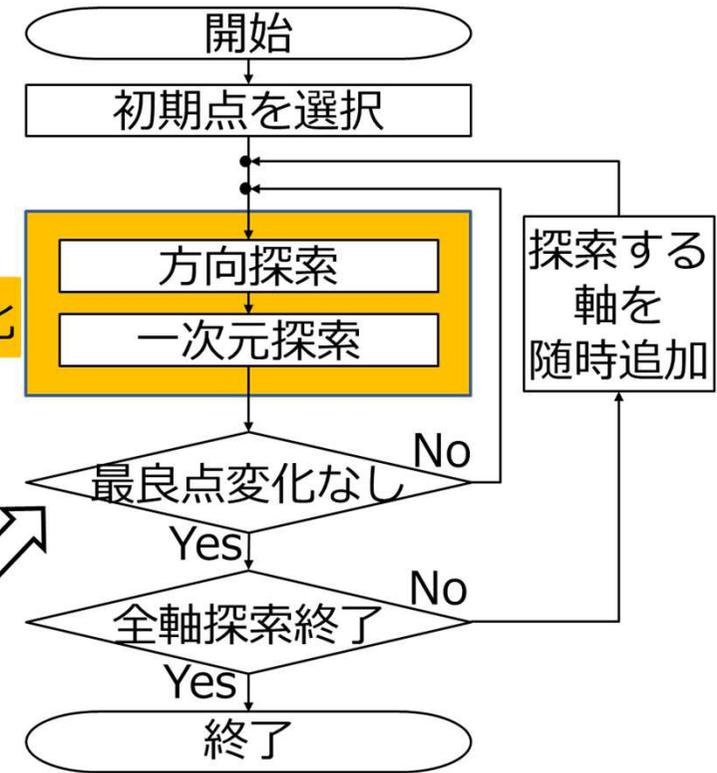
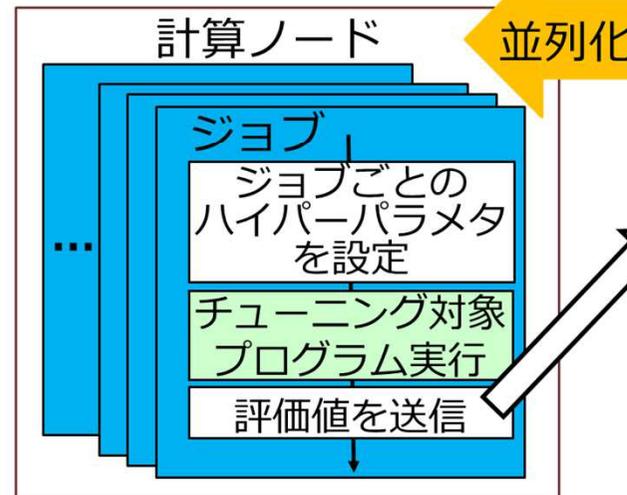
ハイパーパラメタ	取りうる値	パターン数
学習率	$10^{-6}, 5 \times 10^{-6}, 10^{-5}, 5 \times 10^{-5}, 10^{-4}, 5 \times 10^{-4}, 10^{-3}, 5 \times 10^{-3}, 10^{-2}, 5 \times 10^{-2}$	10
w2 (Perceptual損失ウェイト)	$0, 10^{-2}, 5 \times 10^{-2}, 10^{-1}, 5 \times 10^{-1}, 1, 5, 10^1, 5 \times 10^1, 10^2, 5 \times 10^2$	11
w3 (Adversarial 損失ウェイト)	$0, 10^{-5}, 5 \times 10^{-5}, 10^{-4}, 5 \times 10^{-4}, 10^{-3}, 5 \times 10^{-3}, 10^{-2}, 5 \times 10^{-2}, 10^{-1}, 5 \times 10^{-1}$	11
w4 (Style損失ウェイト)	$0, 10^{-2}, 5 \times 10^{-2}, 10^{-1}, 5 \times 10^{-1}, 1, 5, 10^1, 5 \times 10^1, 10^2, 5 \times 10^2$	11
w1(MSE損失ウェイト)	10^{-1}	固定

ATを適用するための技術：並列化

- 複数のハイパーパラメタからなる探索空間において、限定した方向のみを探索
- 新規の探索点が見つからない場合は、探索方向を増やし、探索範囲を拡大
- 方向探索、次元探索に対して、複数ハイパーパラメタの組合せについて、各計算ノードに割り当て、多重ジョブを実行し、同時探索を実施



探索する軸を随時追加



ATを適用するための技術：機械学習における2段階学習

- 通常は、エポック数 2000回を実施
 - これを、事前学習(1000回, 1回のみ)とファインチューニング(250回)の2段階に変更
 - 事前学習：
 - ハイパーパラメータの w_1 のみを0.01, w_2 , w_3 , w_4 はすべて0, バッチサイズは8と設定し,
 - エポック数1000回の実施
 - 事前学習済みトレーニングモデルを取得
 - ファインチューニング：
 - 上記トレーニングモデルをもとに実施
 - ファインチューニングに必要なエポック数を決定するために試行し^{*1}, 250回と設定
- ^{*1}ここでは、学習率を0.0001, w_1 を0.01, w_2 を0.1, w_3 を0.001, w_4 を10に固定し, エポック数を2000まで試行し, ファインチューニングのエポック数250回とできることを確認

計算機環境

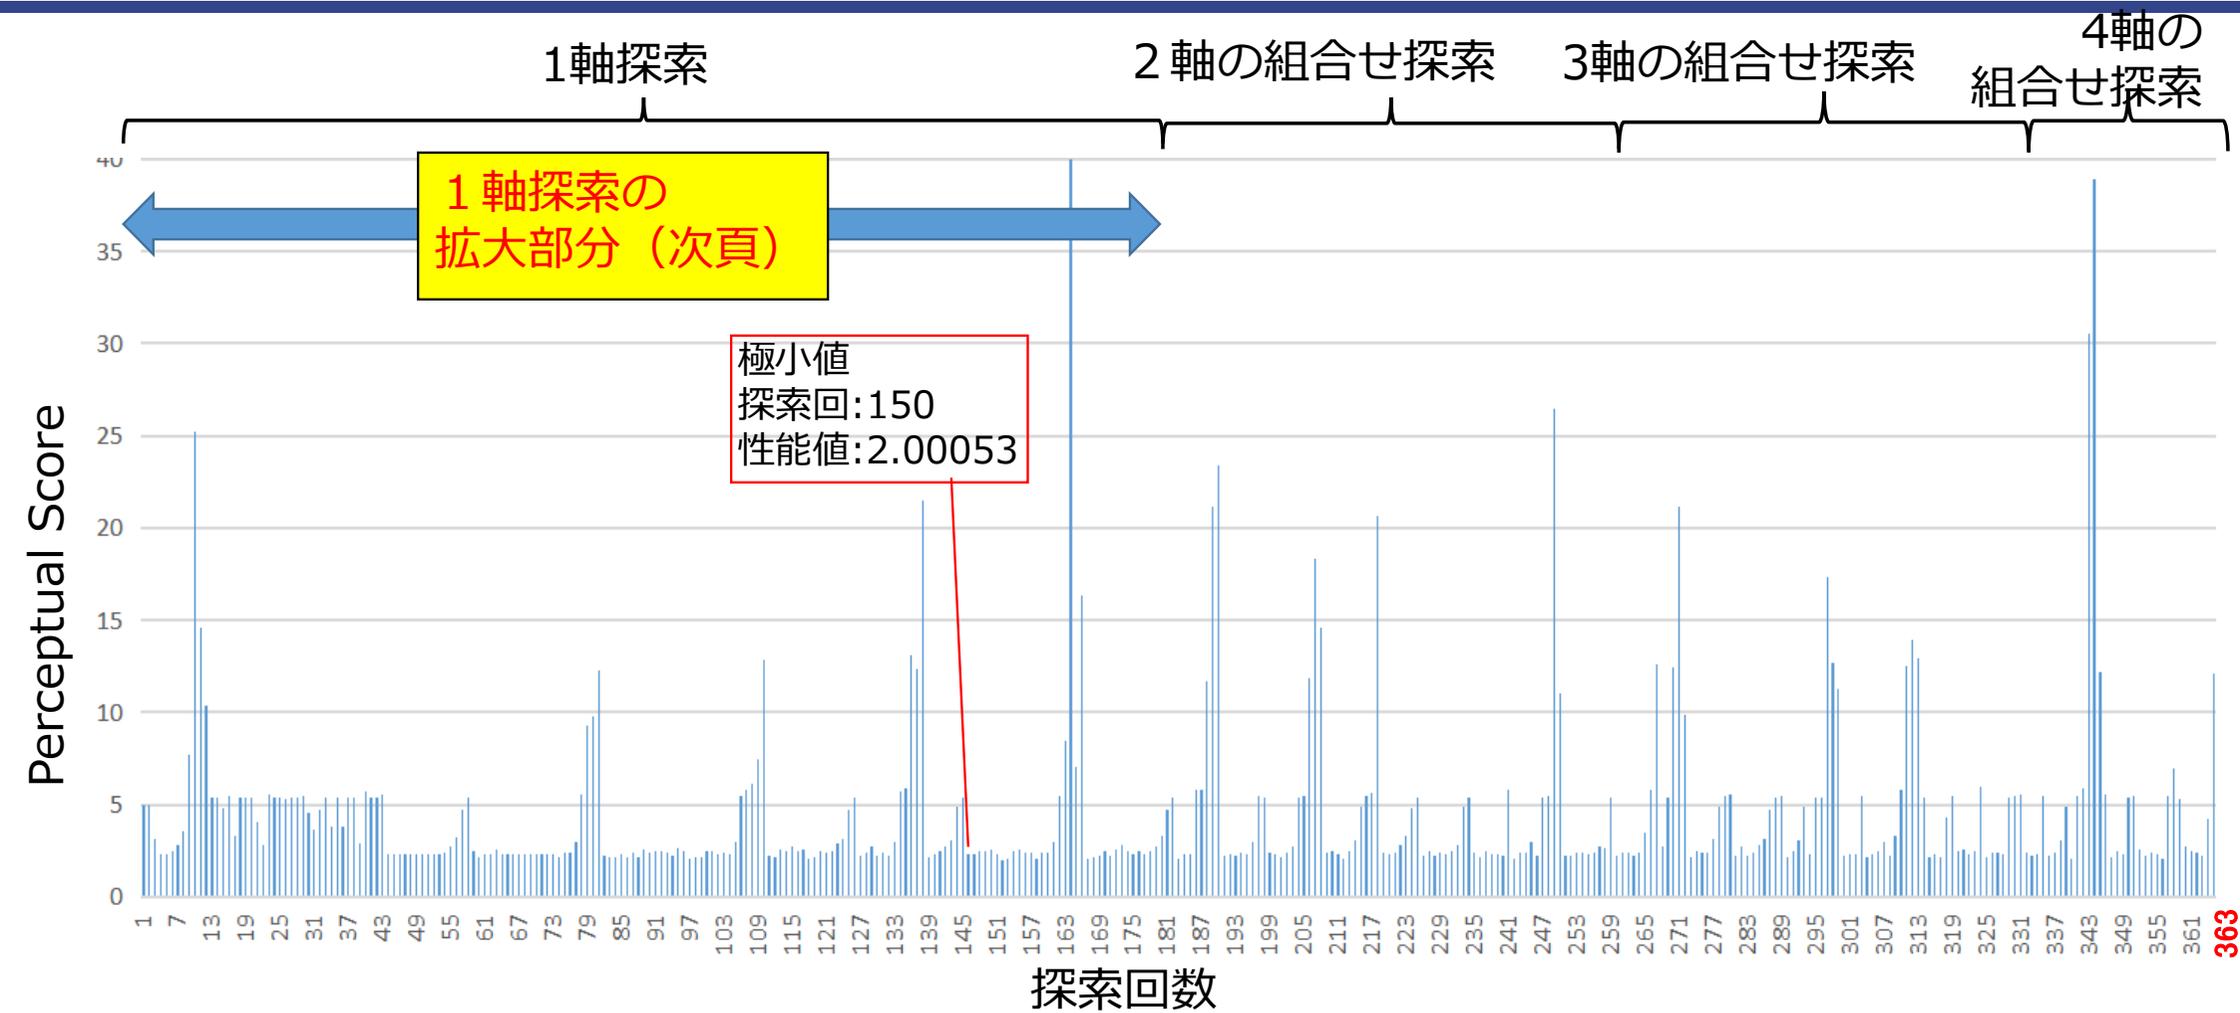
名古屋大学のスーパーコンピュータ「不老」 Type II サブシステム

- ▶ リソースグループはcx-share
- ▶ cx-share: 最大50のジョブを同時に実行可能
- ▶ 1ジョブにつき1GPU を使用

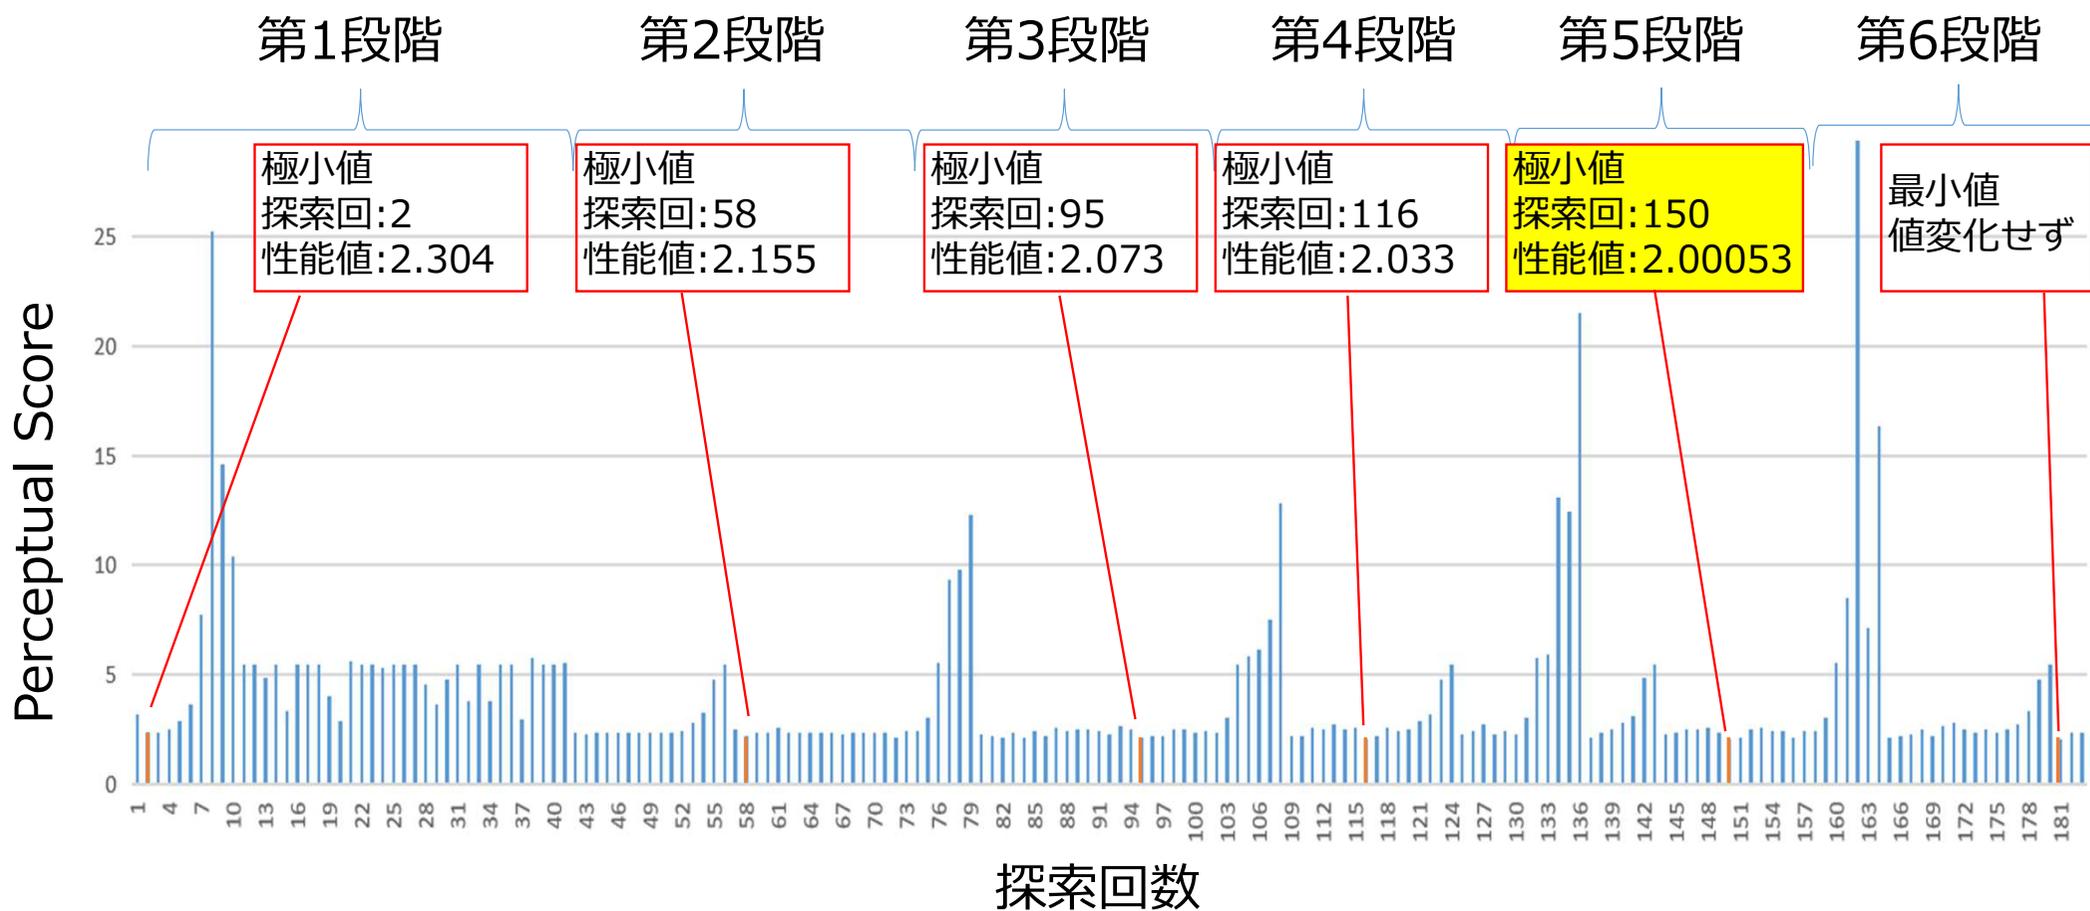
Matlab R2021 b

- ▶ 入力した画像から性能評価値(Perceptual Score)を計算
- ▶ PIRM(Perceptual Image Restoration and Manipulation)プログラムを実行

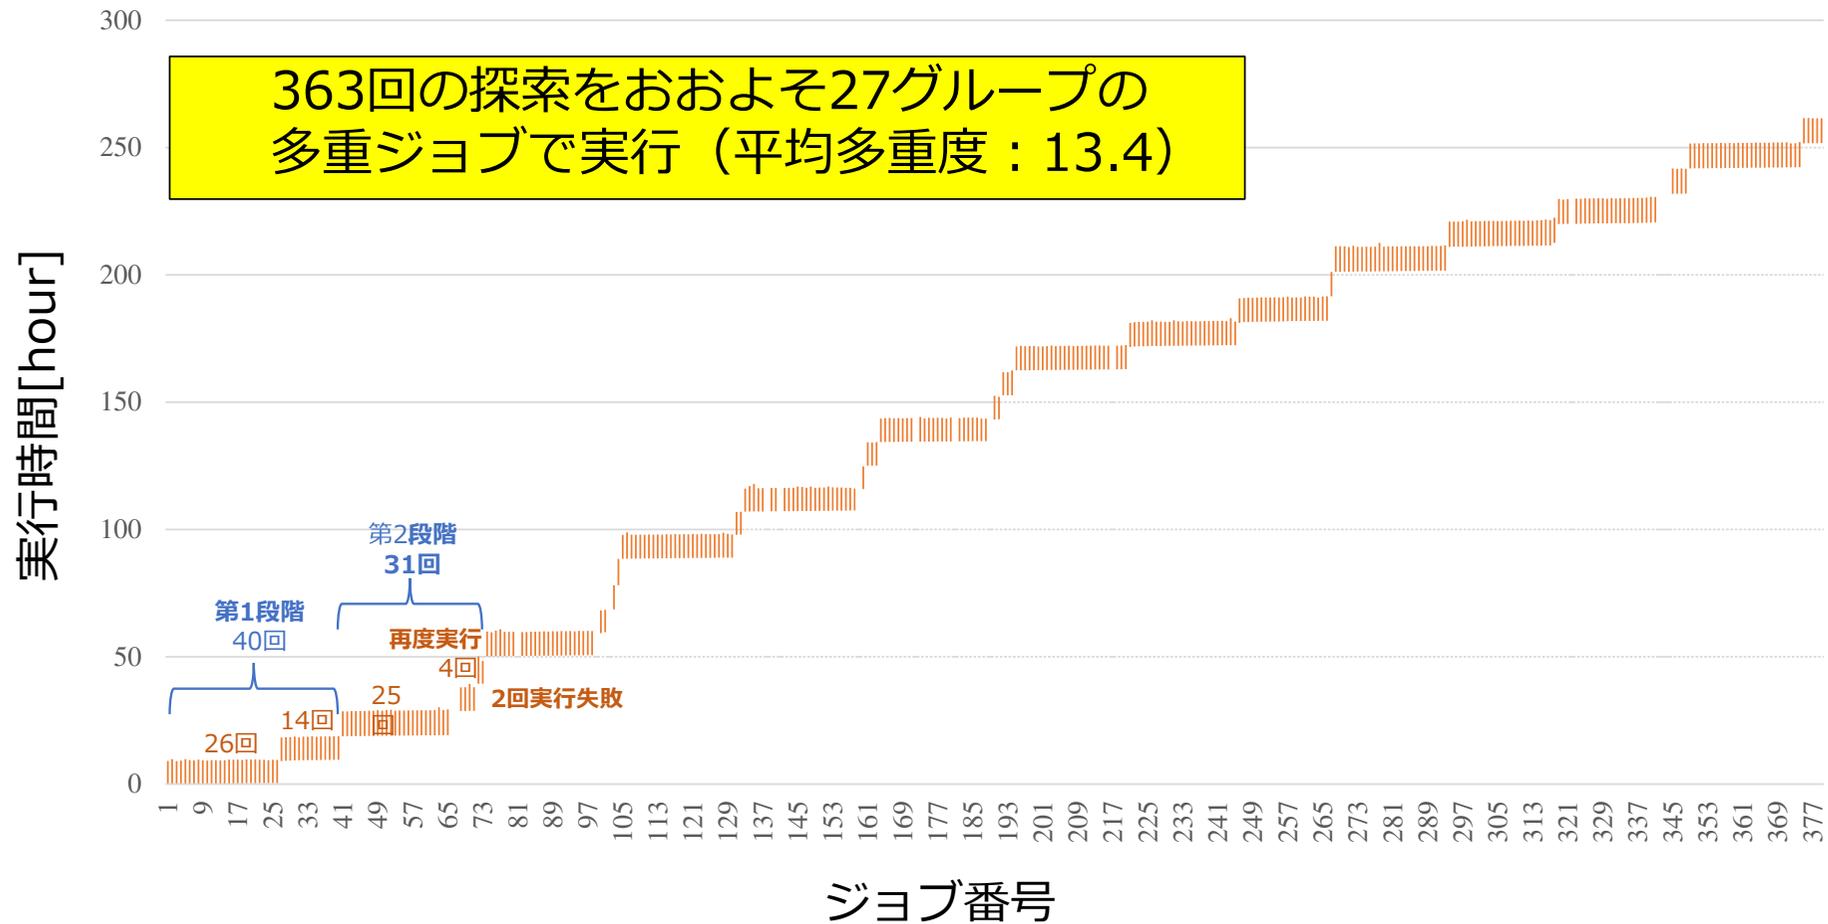
探索履歴



1軸探索



ジョブ実行状況



推定したハイパーパラメータ

	今回のAT	従来値
所要時間	262時間	—
探索回数	363回	—
学習率	0.0001	0.0001
w2(Perceptual損失ウェイト)	50.0	2.0
w3(Adversarial 損失ウェイト)	0.01	0.001
w4(Style損失ウェイト)	0.01	1.0
Perceptual Score:最適値	2.00053	2.04

まとめ

1. 目的：機械学習プログラムのハイパーパラメタ選択の自動チューニング時間の削減
2. 対象：超解像の機械学習プログラムD-DBPNのハイパーパラメタ選択
 - ▶ハイパーパラメタの組み合わせ13,310($= 10 \times 11 \times 11 \times 11$)通り
3. 削減方法と今回の効果
 - ▶2段階チューニング
 - 事前学習とファインチューニングにより毎回のトレーニング回数削減 (2000回 \Rightarrow 250回)
 - ▶並列実行
 - 学習処理をスーパーコンンの多重GPU環境を用いて多重ジョブ実行
 - 363回の探索を27回の多重ジョブで実行 (平均多重度：13.4)
 - ▶2方法の組合せで約1/100に時間を削減
 - ▶評価値(Perceptual Score値)2.04 \Rightarrow 2.00053
4. 今後の課題
 - ▶並列(多重)実行の更なる効率化