

卒業論文

画像の学習に基づく姿勢推定手法の  
学習条件による精度変化の検討

奥川 裕之

指導教員 金田 和文 教授

玉木 徹 准教授

2008年3月17日(月)

広島大学工学部 第二類 電気・電子工学課程  
知的システムモデリング研究室

本研究では、画像の学習に基づく姿勢推定手法の推定精度を検討する。検討の具体的な内容は、学習条件である学習画像枚数や固有空間の次元数を変化させ、その姿勢推定誤差を物体毎に比較することである。検討の結果、学習画像枚数が多い場合より少ない場合の方が精度が良くなる物体が存在した。そのような物体では、相関が高い画像同士が学習画像に含まれると推定精度が向上するという結果を得た。また、固有空間の次元は、物体により精度を保つのに必要な次元数が存在した。

In this research, the presumption accuracy of the posture presumption technique based on the study of the image is examined. A concrete content to examine is to change the number of sheets of the study image that is the study condition and the number of dimension of a peculiar space, and to compare the posture presumption error margins of each object. As a result of the examination, the object to which accuracy improved existed, when the number of sheets of the study image is a little in a lot of cases that are. In such an object, the result that the presumption accuracy improved when the image with a high correlation was included in the study image mutually was obtained. Moreover, the dimension of a peculiar space had a number of dimension necessary to keep accuracy with the object.

# 目次

第 1 章	序論	1
1.1	コンピュータビジョンにおける物体認識	1
1.2	モデルベースの物体認識	1
1.3	アピアランスベースの物体認識	2
1.4	研究目的と論文の構成	3
第 2 章	EbC 法	5
2.1	概要	5
2.2	BPLP 法	5
2.3	情報トラックの付加と固有空間による学習	6
2.4	情報トラック復元によるパラメータ推定	7
2.5	2 枚の画像への集約	7
第 3 章	学習条件変化による検討	9
3.1	実験環境	9
3.2	学習サンプル数変化	10
3.2.1	実験方法	10
3.2.2	実験結果と考察	12
3.3	画像の背景である黒い面積変化の検討	14
3.3.1	実験方法	14
3.3.2	実験結果と考察	15
3.4	画像の相関の検討	18
3.4.1	実験方法	18
3.4.2	実験結果と考察	18
3.5	サンプル角を細かくして検討	21
3.6	固有空間の次元削減	22
3.6.1	実験方法	22
3.6.2	実験結果と考察	22
3.7	累積寄与率	24
3.7.1	実験方法	24
3.7.2	実験結果と考察	25
3.8	RMSE が 100 付近に収束する原因の検討	27

第 4 章 結論	29
第 5 章 謝辞	31
付 録 A COIL-20,COIL-100 の全物体 [5][6]	35
付 録 B 学習条件変化による検討の全ての物体の結果	41
B.1 学習サンプル数変化 (COIL-20) . . . . .	41
B.2 学習サンプル数変化 (始点角 0 度 COIL-100) . . . . .	44
B.3 背景の黒の面積変化 (COIL-20) . . . . .	61
B.4 背景の黒い面積の分散 (COIL-20) . . . . .	64
B.5 画像の相関 (COIL-20) . . . . .	67
B.6 サンプル角を細かくして検討 (COIL-20) . . . . .	70
B.7 固有空間削減 (COIL-20) . . . . .	73
B.8 固有空間削減 (COIL-100) . . . . .	76
B.9 累積寄与率 (COIL-20) . . . . .	93
付 録 C プログラムの使い方 (ユーザ用) 説明書とプログラマ用説明書	97
C.1 開発環境 . . . . .	97
C.2 使用方法 . . . . .	97
C.3 ソースファイルの説明 . . . . .	98
付 録 D 論文中の図・表の対応表	99

# 第1章 序論

## 1.1 コンピュータビジョンにおける物体認識

人が物を見、認識することは、簡単なことであるが、コンピュータで行うには難しいことである。だが、コンピュータに認識させることができれば、人のように多くの行動をさせることが可能となり、人の助けとなると考えられる。例えば、ロボットアームにカメラを付け、そのカメラに写る物体をつかむために姿勢推定がなされれば、うまくつかむことが可能となり、人のかわりに単純作業をさせることが可能となる。このことより、3次元物体の位置や姿勢などのパラメータを二次元画像から推定することは重要である。このような物体認識は、学習により与えられた何らかの知識との照合により実現される。物体認識を照合する知識を大別すると3次元形状モデルと画像の2つに分類できる。それらを用いた手法を次節以降で述べる。

## 1.2 モデルベースの物体認識

モデルベース物体認識とは、照合する学習を3次元形状モデルで行う方法である。具体的には、物体の幾何学モデルやCADモデルのような幾何学的に表現された対象物体の特徴点と、計測された画像から抽出した特長量との対応関係を求めることにより物体認識や姿勢推定を行う。

モデルベースの物体認識のプロセスは、ボトムアップ解析による解析的な認識手法が例にあげられる。ボトムアップ解析とは data-driven な解析とも言われる。ボトムアップ解析では、まず与えられた入力画像に対し、第一段階として線や領域といった画像特徴を抽出する。しかし、このようなプリミティブな線や領域といった特徴量は照合において記述レベルが低く、扱いにくい。そこで、第二段階としてこれらの特徴量を組み合わせて構造化（グループ化）する。さらに第三段階では、構造化された線や領域といった二次元特徴量をエッジや面などの三次元情報へ変換する。そして、あらかじめ知識として与えられたモデルと照合を行い、物体の認識や姿勢推定をする。しかし、画像特徴の抽出が完全に行えないこと、また、特徴との照合のコスト問題によりボトムアップ解析だけでは十分とは言えない。そこで、ボトムアップ解析によりある程度認識対象の具体的なモデルが予測できたあとに、モデルの記述に従い解析を行う手法が必要となる。この解析をトップダウン解析とい

う．このような認識手法で用いられるモデルの代表例として，幾何モデルや一般化円筒モデルがあげられる．

(a) 幾何モデル

物体形状を表現する上で，頂点，エッジ，面，物体をノードとし，それらの間の関係をアークで表現するデータ構造を用いる．このような幾何学的な特徴を用いたモデルは，対象物体の CAD データを直接変換することにより作成することもできるが，形状が複雑になると膨大な記述になる．また，認識において特徴点の組み合わせ問題が生じる可能性がある．[7]

(b) 一般化円筒による表現

一般化円筒とは，中心軸を滑らかな自由曲線として，中心軸に沿って変化する断面形状で表現したモデルである．初期の研究では断面形状を円で近似していたが，その後断面形状として楕円や多角形も使われるようになった．[8]

このような三次元特徴モデルでの照合は，

- 1) 幾何学的に複雑な認識対象のモデル記述は困難
- 2) 画像から特徴量を安定に抽出することが困難
- 3) モデルが複雑になると計算コストが莫大になる

という欠点がある．しかし，認識対象の見た目の大きさ変化や位置・姿勢変化に対して柔軟に認識を行うことができる．また，認識対象の見え方（アスペクト）の変化に対して容易に対処できるという利点がある．

### 1.3 アピアランスベースの物体認識

アピアランスベースの物体認識とは，照合する学習を画像や画像特徴レベルで行う方法である．具体的には，計測した画像とあらかじめ記憶しておいた画像データベースとの比較を行い，どの画像と最も似ているかということにより物体認識や姿勢推定を行う．

アピアランスベースの物体認識は，認識対象となる物体の画像を全て学習する必要がある．濃淡画像を用いた場合，照明条件による画像の変化や物体の姿勢による画像の変化など考慮すべき点が多く，学習サンプル数は積算的に増加する．このことより，記憶容量，照合時間の点で困難とされていた．しかし，固有空間を用いた画像照合法が提案され，少ない記憶容量で学習画像を記憶し，固有空間上で照合することで高速に照合を行うことが可能となった．[9] 近年この手法を応用して，物体の認識，姿勢検出を行うパラメトリック固有空間法 [10] が提案され，この手法は様々なところで応用されている．

このようなアピアランスベースの物体認識では，三次元特徴モデルの照合とは異なり，特徴モデルを用意する必要がなく，幾何学的に複雑な形状の認

識や、顔画像認識なども容易に行うことができる。しかし、画像照合を基本とするため、以下の点で問題がある。

- 1) 認識対象の運動や照明の変化などの自由度に応じて多数の学習サンプルを用意する必要がある。
- 2) 微妙な位置ずれや回転、見た目の大きさ変化などにより誤認識を生じやすい。

## 1.4 研究目的と論文の構成

3次元物体の複雑さに関係なく容易に扱うことができることから、アピアランスの物体認識に着目する。この方法で問題になるのは、パラメータの自由度に対して積算的に増加する学習サンプルを必要とし、計算コストや記憶容量が膨大となるところにある。だが、アピアランス空間の物体認識は、学習と認識の処理を分けて考えることができるので、学習は、パラメータ推定を行う前にあらかじめ行われていれば良く、実用では認識処理の時間が重要になる。そのような、処理速度が速い手法として、Estimation-by-Completion(EbC)法がある。EbC法の流れとしては、まず、学習処理として、画像に物体情報などを表す情報トラックを付加し、固有空間を生成して学習する。パラメータ推定では、入力画像を情報トラックが欠損したものと考え、欠損画像を補間することでパラメータを推定する。画像補間とパラメータ推定の計算を2枚の画像に集約でき、各パラメータの推定を内積演算と三角関数演算で実現できる。このことから、高速なパラメータ推定を行うことができる。だが、EbC法でまだなされていないこととして、学習物体、学習サンプル数などの変化に対する推定精度の検討はなされていない。また、他の手法との比較検討が行われていない。そこで、処理速度の速いEbC法を用いて、様々な学習条件での姿勢推定精度を検討することを目的とする。このような検討を行うことで、活用する場所により精度の良し悪しを変える目安となると考えられる。また、精度変化に法則性があった場合には、新たな姿勢推定手法作成への指針となると考えられる。

本論文の構成は、まず第2章では、本研究で使用しているEbC法について解説する。第3章では、EbC法の学習条件を様々に変化させた検討について述べる。第4章では、本論文のまとめと今後の課題について述べる。



## 第2章 EbC法

### 2.1 概要

EbC法 [1][2] とは、アピアランスベース姿勢推定を、画像に埋め込まれた情報トラックの復元という問題としてとらえ、固有空間法による学習結果を基に BPLP 法 [3] で画像補間することで情報トラックを復元し、パラメータ推定を実現する方法である。この際、EbC法ではこれらの操作の全てを線形演算で記述し、結果的に多自由度のパラメータ推定をパラメータ毎に画像対との相関と三角関数演算で実現している。

### 2.2 BPLP 法

各画素を  $x_1, \dots, x_N$  要素にもつ  $N$  次元の画素ベクトル

$$X = [x_1, x_2, \dots, x_N]^T \quad (2.1)$$

を、一つの学習サンプルとし、 $M$  枚の画像  $\{X_1, X_2, \dots, X_N\}$  を用意する。このような学習サンプルに対して、特異値分解により、 $D$  個 ( $D \leq N$ ) の固有ベクトルを求める。それら表す固有空間を

$$E = [e_1, e_2, \dots, e_D] \quad (2.2)$$

とおく。

ここで、補間するべき失われた画素（欠損画素）を持つ画像  $X'$  が与えられたとき、 $N \times N$  次元単位行列のうち欠損画素に対応する部分だけが 0 である欠損行列

$$\Sigma = \text{diag}(1, 1, \dots, 0, \dots, 1) \quad (2.3)$$

を定義する。そして、画素の欠損を

$$X' = \Sigma X \quad (2.4)$$

とみなし、以下の式で欠損画素値を推定する。

$$\hat{X} = E(E^T \Sigma E)^{-1} E^T X' \quad (2.5)$$

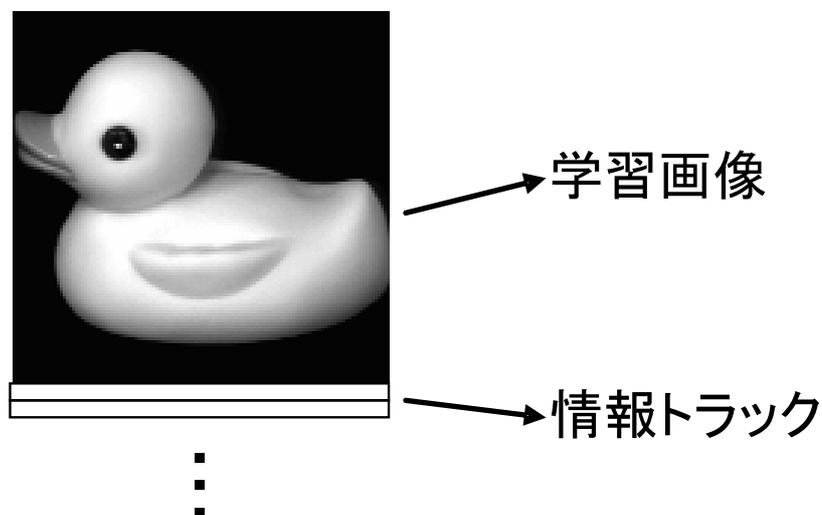


図 2.1: 学習画像  $X$  と情報トラック  $\eta$  の例

### 2.3 情報トラックの付加と固有空間による学習

EbC法は、パラメトリック固有空間法などの教師あり学習と同様に、3次元物体の位置や姿勢角度などのパラメータに従って変化する画像を学習サンプルとして用意する。その学習サンプルに、図 2.1 に示すように画像の1ライン分 (幅  $\omega$ ) の情報トラックベクトル

$$\eta = [y_1, y_2, \dots, y_\omega]^T \quad (2.6)$$

を付加する。この情報トラックベクトルは、物体のパラメータ  $\theta$  と一意に対応するもので、正弦波を用い、

$$y_i = K \cos\left(\frac{2\pi}{\omega}i - \theta\right) + C \quad (2.7)$$

と表す。ここで  $K, C$  は任意定数、 $\omega$  は画像の幅である。この情報トラックベクトルを、画素ベクトルに、

$$\zeta = [x^T, \eta^T]^T \quad (2.8)$$

のように付加する。

このようにしてできた  $M$  枚の学習サンプルに対して、特異値分解を用い、固有空間  $E$  を求める。

## 2.4 情報トラック復元によるパラメータ推定

パラメータ推定を行いたい画像  $X'$  が新たに入力された場合、情報トラック部分はないため、そこを欠損部分と考え B P L P 法により次式で補間できる。

$$\hat{\zeta} = E(E^T \Sigma E)^{-1} E^T \zeta' \quad (2.9)$$

ただし、 $\zeta' = (X^T, 0^T)$ 、 $\Sigma = \text{diag}(\overbrace{1, \dots, 1}^N, \overbrace{0, \dots, 0}^{\omega})$  である。

だが、物体のパラメータを推定する場合、情報トラックの部分だけを取り出せばよい。そこで、固有空間  $E$  を画像部分と情報トラック部分に分け、

$$E = [E_I^T, E_O^T,] \quad (2.10)$$

とすると、式 (2.9) を変形して情報トラック推定値を直接  $X'$  から次式で求められる。

$$\hat{\eta} = E_O(E_I^T E_I)^{-1} E_I^T X' \quad (2.11)$$

情報トラックは正弦波であるため、 $\cos$  と  $\sin$  による同一各周波数のベクトル

$$\omega_c = [\cos 0, \cos\left(\frac{2\pi}{\omega}\right), \dots, \cos\left(\frac{2(\omega-1)\pi}{\omega}\right)]^T \quad (2.12)$$

$$\omega_s = [\sin 0, \sin\left(\frac{2\pi}{\omega}\right), \dots, \sin\left(\frac{2(\omega-1)\pi}{\omega}\right)]^T \quad (2.13)$$

を用意し、それらと情報トラック推定値との内積

$$c = \omega_c^T \hat{\eta} \quad (2.14)$$

$$s = \omega_s^T \hat{\eta} \quad (2.15)$$

を求める。そして、逆正則関数

$$\hat{\theta} = \tan^{-1}\left(\frac{s}{c}\right) \quad (2.16)$$

により位相を求めることができる。これが求めたいパラメータの推定値である。このように計算が簡単にできるので情報トラックに正弦波を用いられている。

## 2.5 2枚の画像への集約

式 (2.14),(2.15) に式 (2.11) を代入して計算すると

$$c = \omega_c^T \hat{\eta} = \omega_c^T E_O(E_I^T E_I)^{-1} E_I^T X' = \{\omega_c^T E_O(E_I^T E_I)^{-1} E_I^T\} X' = \Omega_c^T X' \quad (2.17)$$

$$s = \omega_s^T \hat{\eta} = \{\omega_s^T E_O(E_I^T E_I)^{-1} E_I^T\} X' = \Omega_s^T X' \quad (2.18)$$

とできる。ただし，

$$\Omega_c = \omega_c^T E_O (E_I^T E_I)^{-1} E_I^T \quad (2.19)$$

$$\Omega_s = \omega_s^T E_O (E_I^T E_I)^{-1} E_I^T \quad (2.20)$$

である。 $\Omega_c, \Omega_s$  は，学習によりあらかじめ計算可能なため，パラメータ推定は，二回の内積と一回の逆正則関数の計算のみで行えることから，高速なパラメータ推定を実現できる。

だが，このEbC法では，2.3節で述べた学習の際に，学習サンプル数や固有空間の次元数などの学習条件を変えることで精度が変化することが考えられる。そこで，第3章では，このEbC法の学習条件を変化させて姿勢推定精度の検討を行う。

## 第3章 学習条件変化による検討

この章では、2章で述べた EbC 法の学習条件を変化させた検討について述べる。3.1 節では、検討を行う際の実験環境について述べる。3.2 節では、学習サンプル数を変化させた検討について述べる。3.2 節で得られた、サンプル数が少ない場合よりサンプル数が多い場合で精度が悪くなる原因を探るため、3.3 節では、画像の背景の黒い面積変化の検討について述べる。3.4 節では、3.3 節では原因がわからなかったために、新たに原因を探るために行った、画像の相関の検討について述べる。3.5 節では、3.4 節で得られた、相関が高い画像同士を学習すると精度が良くなるという考えが正しいのか調べるために、サンプル角を細かくして行った検討について述べる。3.6 節では、新たな精度変化の検討として、固有空間を削減した時の精度の検討について述べる。3.7 節では、3.6 節で得られた、固有空間の最低限、精度を保つのに必要な次元数が物体ごとに違う原因を探るために行った、累積寄与率の検討について述べる。最後に、3.8 節で、精度誤差の指標として用いた RMSE の値が 100 付近に収束していることについて述べる。

### 3.1 実験環境

まず、最初に今回検討する際の実験環境について述べる。実験を行うにあたり、学習サンプルとして図 3.1 に示す Columbia Object Image Library (COIL-20, COIL-100)[5][6] を用いた。物体数は、COIL-20 は 20 物体、COIL-100 は 100 物体である。全ての物体については、付録 A にのせる。これらの画像の解像度は  $128 \times 128$  画素であり、COIL-20 はグレースケール画像、COIL-100 はカラー画像である。だが、EbC 法を適用する際の画像ベクトルの生成は、グレースケール画像の画素値と同様にカラー画像の RGB 値を

$$X = [x_{R,1}, x_{G,1}, x_{B,1}, \dots, x_{R,128 \times 128}, x_{G,128 \times 128}, x_{B,128 \times 128}]^T \quad (3.1)$$

のように並べることで生成した。その後の処理はグレースケール画像と同様にカラー画像へも適用した。学習のための 3 次元物体の運動のパラメータは、物体の鉛直軸周りの回転とした。COIL-20, COIL-100 で提供されている画像は共に、 $5[\text{deg}]$  刻みで一周 72 ステップである。今回、 $i$  度の学習サンプル画像を  $x_i$  と定義した。例えば、5 度の学習サンプル画像ならば、 $x_5$ 、10 度の学習サンプル画像ならば、 $x_{10}$  である。

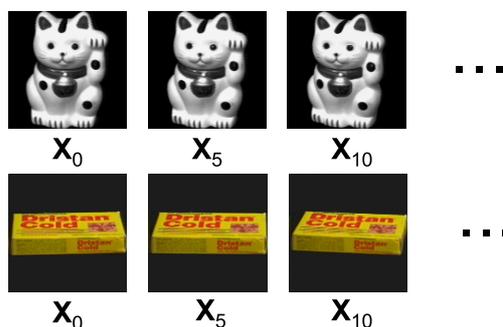


図 3.1: 学習サンプル (上: COIL-20 object4 下: COIL-100 object1)

また、パラメータに対応する情報トラックの正弦波を、画像では負の値を表現することはできないので、 $K = 127, C = 127$  に設定し、 $\eta$  の最小値と最大値をそれぞれ 0 と 254 に抑えた。そして、これを学習サンプル画像  $X$  に追加して学習用画像  $\zeta$  を生成した。そして学習用画像  $\zeta$  を複数枚用いて作った行列に特異値分解を用いることで固有空間  $E$  を計算した。

次節より、学習条件変化による精度変化について検討について述べる。

## 3.2 学習サンプル数変化

まず最初に、精度変化の検討として、学習サンプル数変化における検討を行った。これは、学習サンプル数が多いほど精度が高くなり、少なくなるほど精度が悪くなると推測される。だが、その精度変化が、本当にそのように変化するのか、また、どのくらいの枚数まで精度が保てるのか、わかっていない。また、同じ枚数を学習したとしても、学習する画像により精度が変化するのか、わかっていない。そこで、サンプル数と学習サンプルを決定する基準となる画像の始点 (始点角) を変化させることで検討を行った。

### 3.2.1 実験方法

サンプル数変化の模式図を図 3.2 に示す。まず、学習サンプル数の変化を、学習の間隔を等間隔 (サンプル角  $i$ ) とし、その間隔を変化させることで行った。サンプル角は、等間隔とするため、360 の素数とし、

$$i = 5, 10, 15, 20, 30, 40, 45, 60, 90, 120 \quad (3.2)$$

とした。また、枚数を同じで学習画像を変化させるために、始点角  $s$  を変化させた。始点角は、0 度から、始点角の 5 度手前までとした。これは、始点

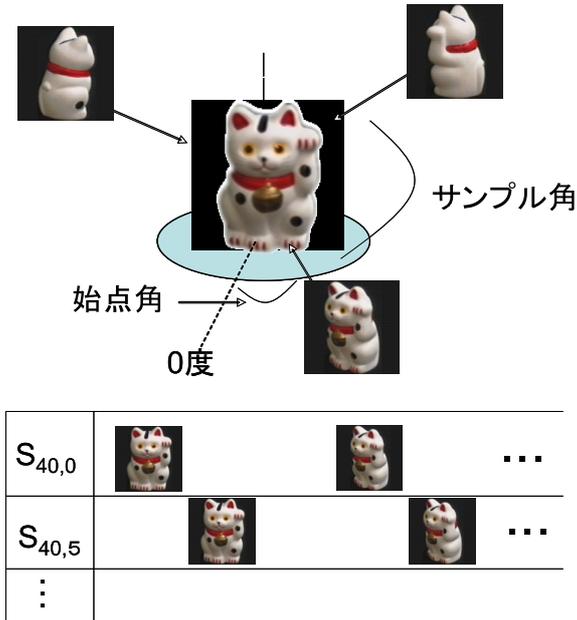


図 3.2: 学習サンプル数変化の様式図

角がサンプル角と同じになると、始点角 0 度と同じ画像を学習することになるからである。

今回用いた学習サンプル画像群のことを学習セットとし、以下の式で定義した。

$$S_{i,s} = \{X_{ik+s}\} \quad k = 0, 1, \dots, n_i - 1 \quad (3.3)$$

$n_i$  はサンプル角  $i$  度の時の学習サンプル数である。具体的に学習セットの例を挙げると、サンプル角が 40 度で始点角が 0 度の時は、学習セットが  $S_{40,0} = 0, 40, 80, 120, \dots, 280, 320$ 、サンプル角が 40 度で始点角が 5 度のときは、学習セットが  $S_{40,5} = 5, 45, 125, \dots, 285, 320$  となる。

今回、精度評価としては、次式を用いた。

$$RMSE_{i,s} = \sqrt{\frac{1}{72 - n_i} \sum_{x_j \notin S_{i,s}} (\hat{\theta}_j - \theta_j)^2} \quad (3.4)$$

$\theta_i$  は実際の画像の角度、 $\hat{\theta}_i$  は推定値である。この計算では、学習した画像を、推定画像とした結果は必ず誤差が 0 となることから、学習画像の推定誤差を含まないようにしている。

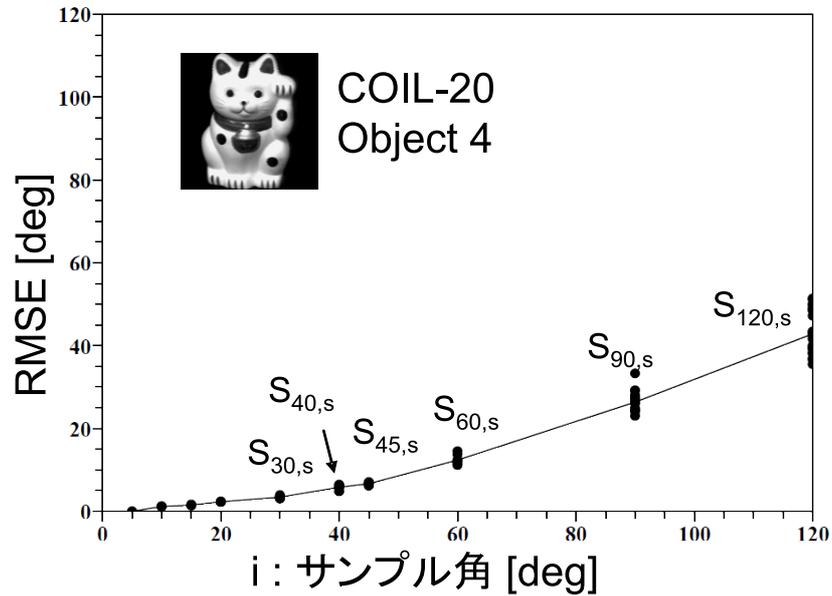


図 3.3: 学習サンプル数変化 (標準)

### 3.2.2 実験結果と考察

実験結果を図 3.3, 3.4, 3.5 に示す。(全ての物体の結果は, 付録 B.1, B.2 を参照) これらのグラフは, 縦軸を RMSE, 横軸をサンプル角としており, サンプル角が大きくなるにつれて, サンプル数は減少する。同じサンプル角でプロットしてある複数の点は, 同じサンプル角であるが, 始点角が異なる, つまり学習画像が異なっている場合での精度変化を表している。

まず, 図 3.3 を見てみると, 推測したとおりに学習枚数が少なくなるごとに, 精度が悪くなっている。だが, 図 3.4 のように, 推測とは異なり, サンプル数が多い 9 の場合より, サンプル数が少ない 8 や 6 の場合のほうが精度が良くなる物体も存在した。また, 図 3.5 のように, サンプル数が少ない 3 でも精度を保てる物体が存在した。つまり, 物体により精度を保てる画像枚数は異なることが言え, また, データ量を減らすために, 単純に画像枚数を少なくするべきではないことが言える。

また, 学習枚数が同じで学習する画像を変えると物体や枚数により精度は変わるが, それほど大きなものではないことがわかる。そのことより, 学習する画像はそれほど考えて選ぶ必要がないことが言える。

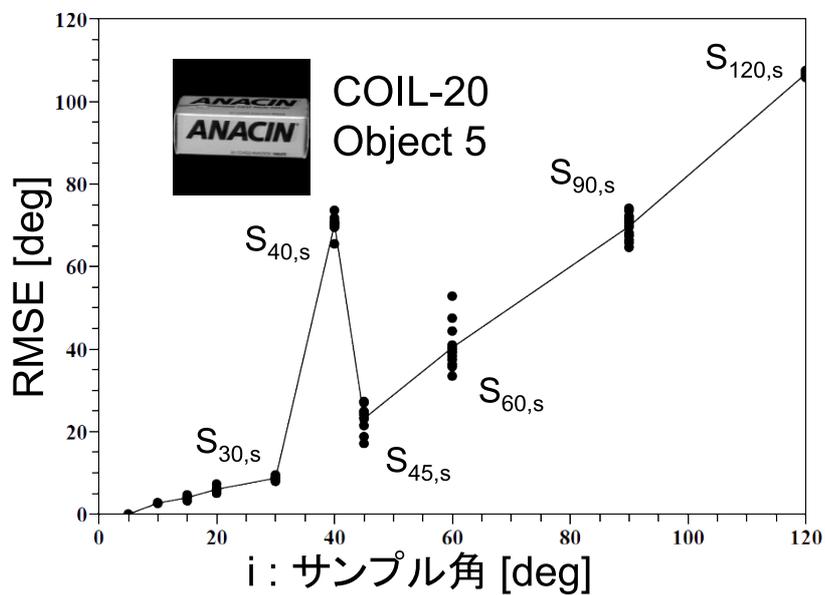


図 3.4: 学習サンプル数変化 (サンプル数が多い場合より少ない場合で精度が良くなる物体)

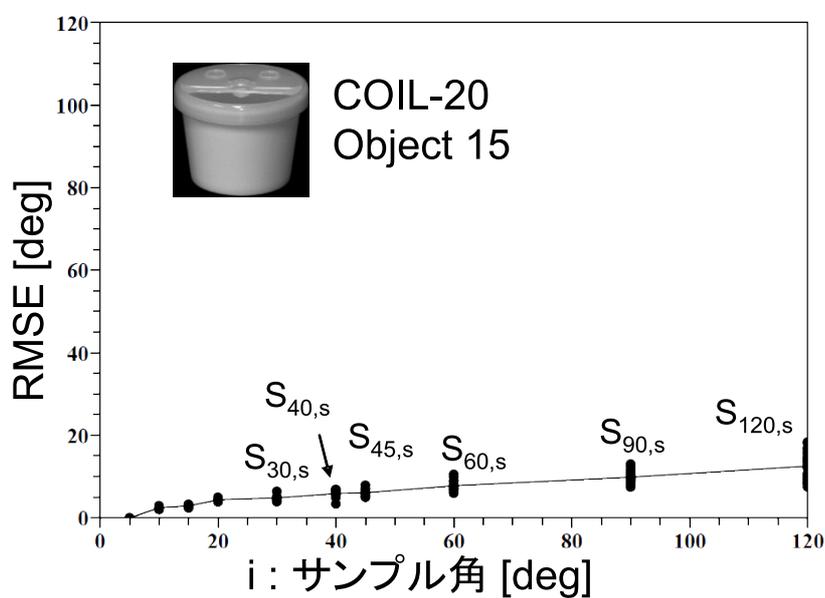


図 3.5: 学習サンプル数変化 (サンプル数が少ない場合でも精度が良い物体)



図 3.6: 背景の黒い面積の例

### 3.3 画像の背景である黒い面積変化の検討

3.2 節では、サンプル数が多い場合より少ない場合のほうが精度が良くなった物体が存在することについて述べた。そこで、その原因を探るために、今回使用している画像である COIL-20 の特徴の検討を行った。これは、画像の学習に基づく姿勢推定手法では、推定したい画像と、学習セットの中の、どの画像が似ているかで推定が決まるからである。

そこで、まず、画像の見た目の変化をしてみる。すると、サンプル数が多い場合より少ない場合のほうが精度が良くなった物体では、画像内の物体に拡大、縮小が大きく見られた。例えば、図 3.6 では、 $X_{90}$  の方が物体が大きくなっていることがわかる。その拡大、縮小の変化によって、背景の黒い面積が少なくなったり多くなったりしていることがわかる。その黒い面積の変化により、いままで、背景だったところが物体に、物体だったところが、背景にといった変化が起こり、その変化は、画像ベクトルとしては、影響が大きい(例えば、いままで背景だった画素値 0 のところが、物体の画素値 100 に変化)。よって、この変化が原因でサンプル数が多い場合より少ない場合のほうが精度が良くなったのではと考えた。そこで、背景の黒い面積変化の検討を行った。

#### 3.3.1 実験方法

物体ごとに、画像の背景である黒の面積の変化を調べることで検討を行った。今回の実験では、画像の背景の黒い面積を、画像の左すみの画素値と同じ画素値のものの画素数とした。その画素数の変化を物体ごとに見ることで検討を行った。

また、推定精度と背景の黒面積との関係性を調べるために、3.2 節の際用いた学習セットの画像の黒面積の分散とその学習セットでの推定精度である RMSE の関係性の検討を行った。これは、黒面積の分散の広がりにより精度

が変化し、その変化が原因でサンプル数が多い場合より少ない場合のほうが精度が良くなったと考えたからである。

### 3.3.2 実験結果と考察

物体ごとの黒面積変化の結果を図 3.7,3.8,3.9 に示す。(全ての物体の結果は、付録 B.3 を参照) これらのグラフは、縦軸が背景の黒い面積を表し、横軸が画像の角度を示している。つまり、物体を一周する間の画像内の物体の拡大縮小による、背景の黒い面積の変化を表している。例えば、図 3.7 では、画像の角度が 0 度の場合では、 $X_0$  の画像の背景の黒い面積、画像の角度が 90 度の場合では、 $X_{90}$  の画像の黒い面積を示している。

サンプル数が少なくても精度の良い物体 (図 3.8) では、他の物体 (図 3.7) と比べて変化が少ない結果となった。また、サンプル数が多い場合より少ない場合のほうが精度が良くなった物体 (図 3.9) では、黒い面積の最大と最小の差が大きいものが多い結果となった。また、ほとんどの物体で、0 度の画像から 180 度の画像の黒面積の変化と 180 度の画像から 360 度の画像の黒面積の変化が似ている結果となった。だが、これらの結果からサンプル数が多い場合より少ない場合のほうが精度が良くなった原因はわからなかった。

また、もう 1 つの検討である学習セットごとの黒面積の分散と RMSE の関係を示した結果を図 3.10 に示す。(全ての物体の結果は、付録 B.4 を参照) このグラフの縦軸は RMSE、横軸は黒い面積の分散である。また、色の変化は、サンプル角が 40,45,60,90,120 度で色を変えてプロットしている。同じ色のプロット点は、サンプル角は同じで、始点角を変化させたものである。推測では、黒い面積の分散の変化で精度が変わると考えていたが、このグラフを見ると、ほとんど変化は見られなかった。つまり、黒い面積の分散の広がりや精度に、関係性は見られなかった。

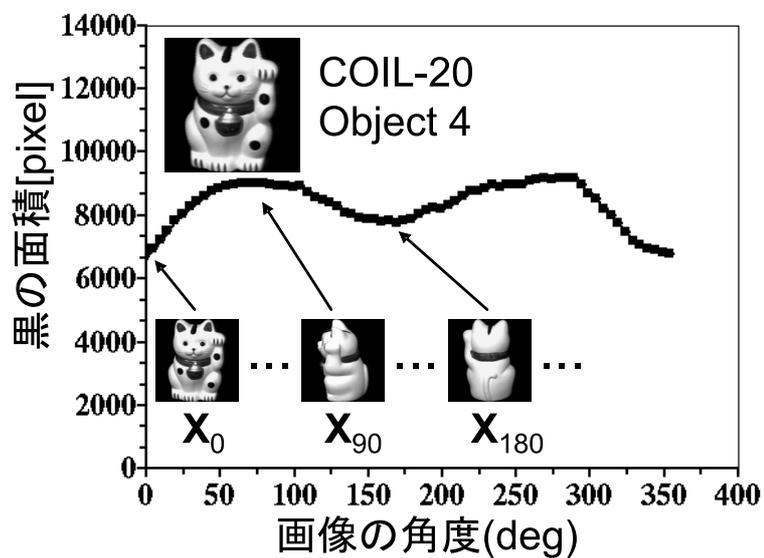


図 3.7: 背景の黒い面積の変化 (標準)

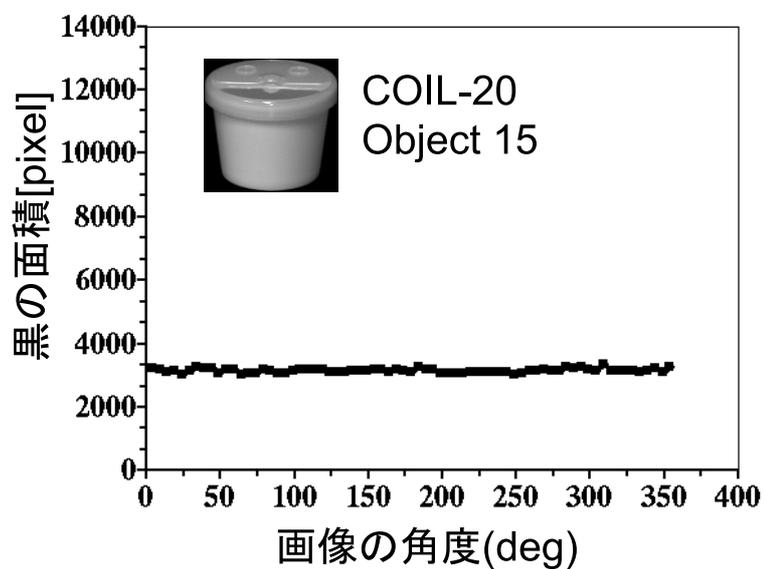


図 3.8: 背景の黒い面積の変化 (サンプル数が少ない場合でも精度が良い物体)

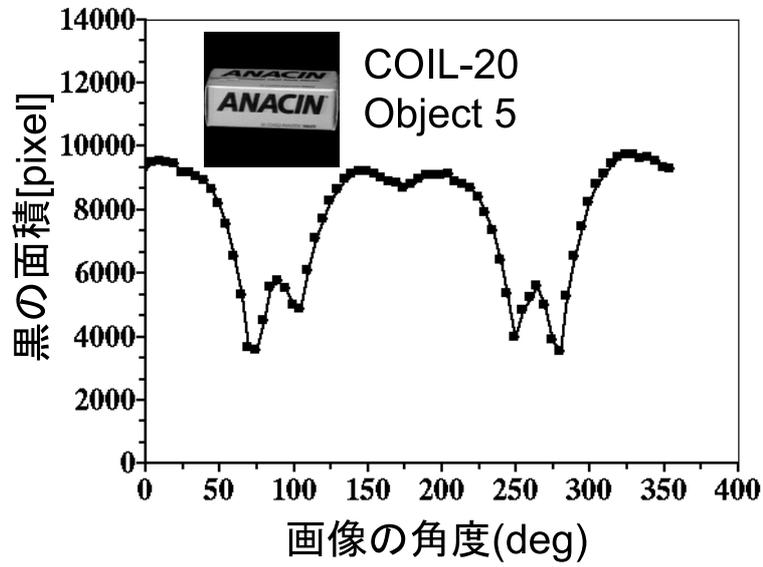


図 3.9: 背景の黒い面積の変化 (サンプル数が多い場合より少ない場合で精度が良くなる物体)

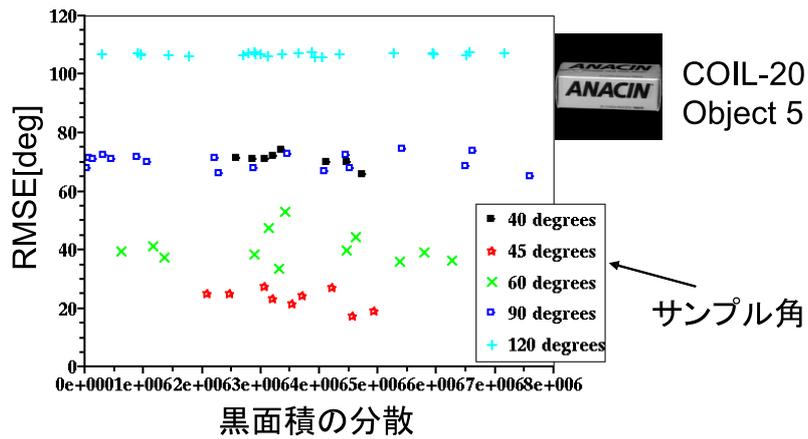


図 3.10: 背景の黒い面積の分散と RMSE の関係

### 3.4 画像の相関の検討

3.3節では、サンプル数が多い場合より少ない場合のほうが精度が良くなった原因を探るために、背景の黒い面積変化について検討を行ったが、その原因はわからなかった。そこで、さらに原因を探っていくために、画像の類似度の尺度となる画像の相関の検討を行った。これは、画像の学習に基づく姿勢推定手法では、推定したい画像と、学習セットの中の、どの画像が似ているかで推定が決まる。そのことから、物体ごとに画像の相関を調べることで物体ごとの特徴がわかり、そのことでサンプル数が多い場合より少ない場合のほうが精度が良くなった原因がわかると考えたからである。

#### 3.4.1 実験方法

今回画像の相関として、以下の式を計算した。

$$C_{i,j} = \frac{X_i^T X_j}{\|X_i\| \|X_j\|} \quad (3.5)$$

この式は、画像  $X_i$  と  $X_j$  の相関を意味している。 $C_{i,j}$  が1に近いほど相関が強くなり、0に近いほど相関が弱くなる。

#### 3.4.2 実験結果と考察

実験結果を図3.11,3.12,3.13に示す。(全ての物体の結果は、付録B.5を参照) この図3.11はサンプル数が多い場合より少ない場合のほうが精度が良くなった物体の相関の数値を画像として表現したもので、色が白ければ相関が高く、黒ければ相関が低くなっている。横軸を*i*度、縦軸を*j*度とし、座標の(*i*,*j*)が*i*度の画像と*j*度の画像の相関の値の色となっている。真ん中の対角線の白い線は同じ画像同士(*i=j*)の相関を表し、最大値となっている。その対角線以外にも値の高い白い対角線が見て取れる。この線は、180度ずれたところの値である(例えば、*i*が0度の時は*j*が180度のところ)。つまり、全ての画像でその画像付近と180度ずれたところで、相関が高くなっている。

また、精度が悪くなっていたサンプル数9、つまりサンプル角が40度の時の学習セット  $S_{40,0} = \{0, 40, 80, 120, \dots, 280, 320\}$  の0度,40度,200度の画像と他の画像との相関を表したものを図3.12に示す。縦軸は、式3.5の値を示しており、横軸は角度*j*を示している。色の違いは、基準となる画像の違いを示しており、例えば、黒いプロット点は、0度の画像と他の画像との相関を表している。このグラフを見ると先ほど述べた相関が高い画像同士(図3.12では200度の画像に対して20度)が学習画像に含まれていない。そのことで、20度の画像を推定する際に理想では、0度と40度の影響を一番受けて20度と推定されてほしいところで、200度の影響を一番受ける結果となり、推定

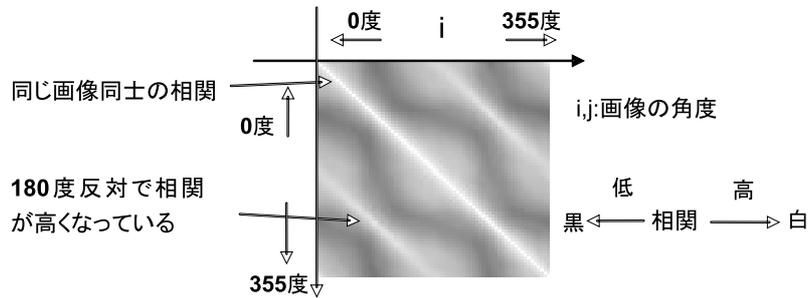


図 3.11: 画像の相関 (COIL-20 obj5)

値が 200 度付近と実際の値との誤差が大きくなることで精度が悪くなったと考えられる。

また、精度が良くなっていたサンプル数 8、つまりサンプル角が 45 度の時の学習セット  $S_{45,0} = \{0, 45, 90, 135, \dots, 270, 315\}$  の 45 度, 90 度, 225 度, 270 度の画像と他の画像との相関を表したものを図 3.13 に示す。縦軸は、式 3.5 の値を示しており、横軸は角度  $j$  を示している。色の違いは、基準となる画像の違いを示しており、例えば、黒いプロット点は、45 度の画像と他の画像との相関を表している。このグラフを見ると先ほど述べた相関が高い画像同士 (図 3.13 では 45 度の画像に対して 225 度) が学習画像に含まれている。そのことで、先ほどのような現象は起こっていない。そのことで、サンプル数が多い 9 の時より精度が良くなっていると考えられる。それが、学習画像枚数が少ない場合より多い場合の方が精度が悪くなる原因となったと考えられる。

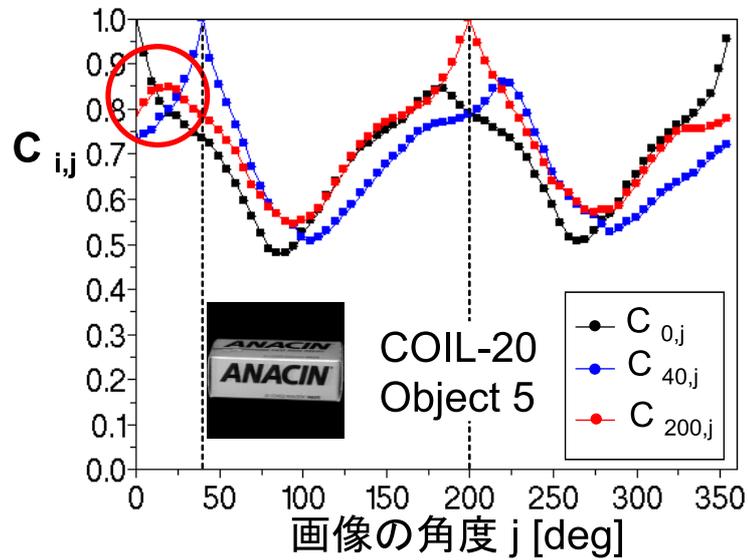


図 3.12: 画像の相関変化 (サンプル角 40 度  $i = 0, 40, 200$ )

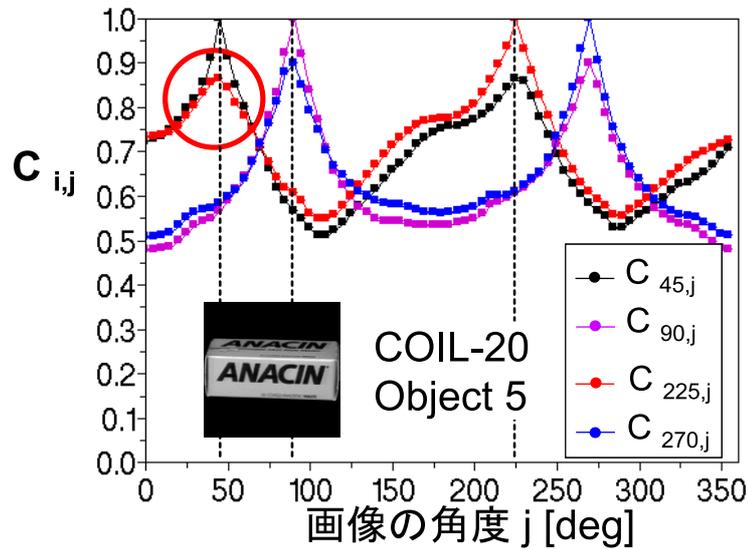


図 3.13: 画像の相関変化 (サンプル角 45 度  $i = 45, 90, 225, 270$ )

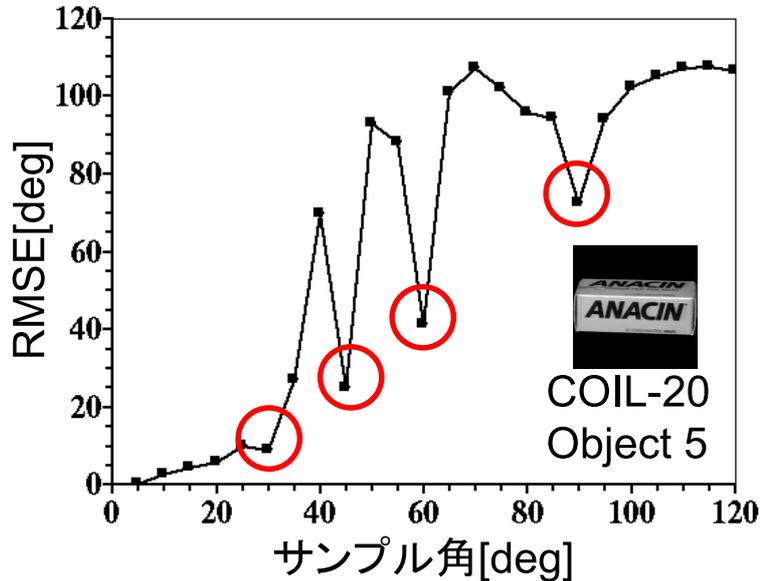


図 3.14: サンプル角を細かくした時の RMSE の変化 (COIL-20 obj5)

### 3.5 サンプル角を細かくして検討

3.4 節では、相関が高い画像同士が学習されていると精度が良くなると述べた。だが実際、その考えのように精度が良くなるのかわからないので、それを検証するために、よりサンプル角を細かくし、検討を行った。これは、いままでのサンプル数の変化だと、180 度ずれた相関が高い画像同士が学習されていなかったのがサンプル角 40 度の時だけであった。そこで、よりサンプル角を細かくすることで、相関が高い画像同士が学習されていないものの精度を検討することで、相関が高い画像同士が学習されていると精度が良くなるという考えが本当なのか検証を行った。

今回は、始点角を 0 度と固定し、サンプル角を 0 度から 5 度ずつ 120 度まで変化させた。

実験結果を図 3.14 に示す。(全ての物体の結果は、付録 B.6 を参照) この図は、縦軸が RMSE で、横軸がサンプル角になっており、サンプル角が大きくなるにつれて、サンプル数は少なくなる。この結果、相関が高い画像同士が学習されている 45 度、60 度、90 度で精度が良くなり、相関が高い画像同士が学習されていない角度で、それらの角度より学習枚数の多い 35 度や 40 度では、精度が悪くなっている。このことより、相関が高い画像同士が学習されていると精度が良くなることが言える。

### 3.6 固有空間の次元削減

3.5節までは、学習条件変化の一つであるサンプル数変化による精度の検討について述べてきた。だが、精度が変化する学習条件は他にも存在する。

そこで、新たな精度変化の検討として、固有空間の次元を削減することで検討を行った。これは、EbC法では、学習の際に固有空間を生成する。参考文献 [2] ではその固有空間の次元をある程度削減したほうが、精度が良くなる結果となっている。だが、どのくらい次元を削減すると、一番精度が良くなるのかわかっていない。そこで、固有空間の次元を削減して検討を行った。

#### 3.6.1 実験方法

実験として、まず、始点角を0度と固定し、3.2節のように、サンプル角変化させて、固有空間を生成する。その際、作成された固有空間の次元は、サンプル数と同じとなる。その後、作成した固有空間の次元を1次元ずつ削減し、その度にRMSEを計算した。次元削減は、次元が1次元になるまで行った。今回、精度評価としては、次式を用いた。

$$RMSE_{i,0} = \sqrt{\frac{1}{72} \sum_{i=1}^{72} (\hat{\theta}_j - \theta_j)^2} \quad (3.6)$$

$\theta_i$  は実際の画像の角度、 $\hat{\theta}_i$  は推定値である。今回は、学習した画像を、推定画像とした結果でも固有空間の次元を下げると、誤差が変化すると考えられるので、学習画像の推定誤差も含んでいる。

#### 3.6.2 実験結果と考察

実験結果を図3.15,3.16に示す。(全ての物体の結果は、付録B.7,B.8を参照) これらの図は、縦軸にRMSE、横軸に固有空間の次元数となっており、色の違いは、サンプル角の違いを表している。これらの図は、サンプル角が5,10,15度の時の次元削減を示している。サンプル角が5度の時は、学習サンプル数は、72枚となるので、次元数は72次元から始まっており、サンプル角が10度では、サンプル数が36枚だから36次元、15度ではサンプル数が24枚だから24次元から始まっている。

これらの図を見ると、次元を削減しても精度が良くなっていないことがわかる。この原因として、次元がもともと少な過ぎることがあげられる。参考文献 [2] では、EbC法を3自由度で行っており、次元数は、最大で22500次元となっており、その次元が30から40次元付近で精度が良くなっている。つまり、最大の約0.2パーセントほどの次元で精度が良くなる結果となってい

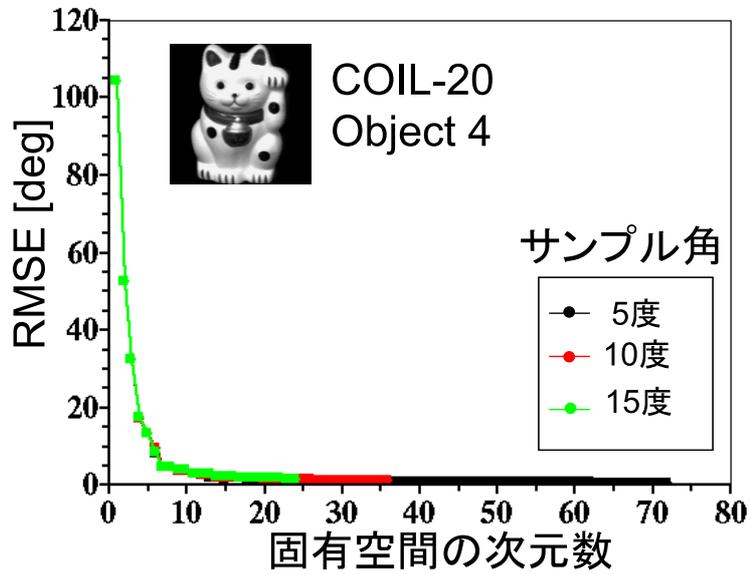


図 3.15: 固有空間削減による精度変化 (COIL-20 obj4)

る。だが、今回の実験では、最大の次元でも、72次元であるため、その0.2パーセントは1次元にも満たない。そのことが、原因だと考える。

また、物体が同じであれば、学習枚数が違ってても、同じぐらいの次元で精度が悪くなっているのわかる。つまり、物体により、精度を保つための最低限必要な次元数が存在するのがわかる。例えば、図3.15では、7次元付近で精度が急激に悪くなり始めているし、図3.16では、10次元付近で精度が急激に悪くなり始めている。だが、その次元は物体により異なり、物体によりその次元が変わる理由はわからない。

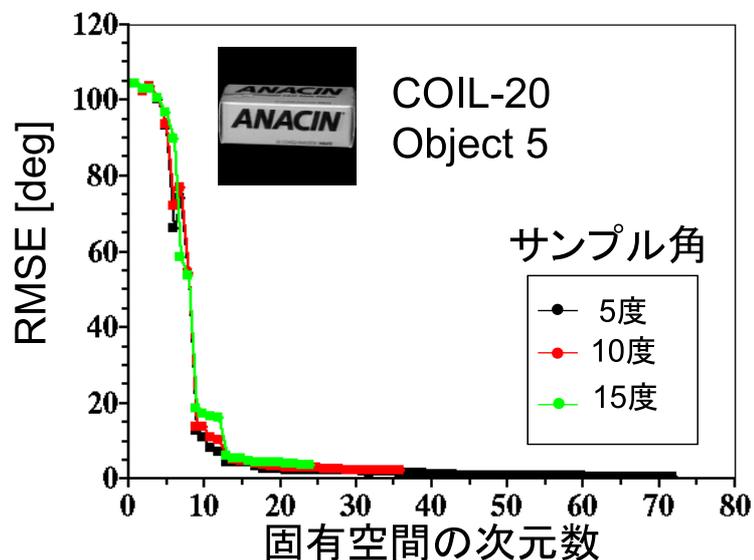


図 3.16: 固有空間削減による精度変化 (COIL-20 obj5)

### 3.7 累積寄与率

3.6 節の検討で、物体により精度を保つ最低限必要な次元数が存在し、その次元数が物体により違うことを述べた。だが、その原因がわからなかった。そこで、その原因を探るために、物体ごとの累積寄与率の計算を行った。累積寄与率とは、もともと次元を削減する際にどのくらい削減するかの目安として計算されてきた。だが、その変化がどのように変化するのか、またどのくらいの累積寄与率まで精度が保てるのかわかってはいない。しかし、3.6 節で述べたように、精度を保つために必要な次元数があるなら、精度を保つのに必要な累積寄与率があるのではと考えた。そして、その精度を保つ累積寄与率に下がるまでの減衰の仕方が、物体により異なり、そのことで、精度を保つ最低限必要な次元数が違う原因となったと考えた。そこで、累積寄与率の検討を行った。

#### 3.7.1 実験方法

累積寄与率を以下の式で計算した。

$$c.p.(D) = \sum_{i=1}^D \lambda_i / \sum_{i=1}^R \lambda_i \quad (3.7)$$

この式は  $D$  次元の累積寄与率を求める式であり,  $R$  は最大次元を表す. 累積寄与率は  $D = R$  の時, 最大で 1 となる.  $\lambda$  は固有ベクトルに対応する固有値であり ( $\lambda_1$  は  $e_1$  に対応),  $\lambda_1 \geq \lambda_2 \geq \dots \lambda_D$  となっている.

実験方法としては, 始点角を 0 度と固定し, サンプル角を 3.2 節のように変化させて固有空間を生成する. この固有空間を生成するのに用いられる特異値分解では, 固有値も求まる.  $D$  を 1 から  $R$  まで変化させながら, その固有値を用いて, 累積寄与率を計算する.

### 3.7.2 実験結果と考察

実験結果を図 3.17, 3.18 に示す. (全ての物体の結果は, 付録 B.9 を参照) これらのグラフは, 縦軸が累積寄与率, 横軸が固有空間の次元  $D$  となっている. 色の違いは, サンプル角を示しており, 例えば, プロット点が黒のサンプル角 5 度では, 累積寄与率は 72 次元で 1 となり, サンプル角 10 度では, 累積寄与率は, 36 次元で 1 となる. 点線は, その物体での, 精度を保つ必要な次元数を示している.

結果を見ると, 物体により, 累積寄与率の変化は異なり, 必要次元数が多いものの方が, 累積寄与率が小さな値となった. また, 次元増加にともなう累積寄与率の上がり方は, 必要次元数が多いものの方が, なだらかに変化している. また, 精度を保つ必要な次元数での累積寄与率を見ると, どの物体でも, どのサンプル数でも累積寄与率はどれもまばらで, 一貫性はなかった. つまり, 累積寄与率と精度を保つ次元数には, 関係性は見られなかった.

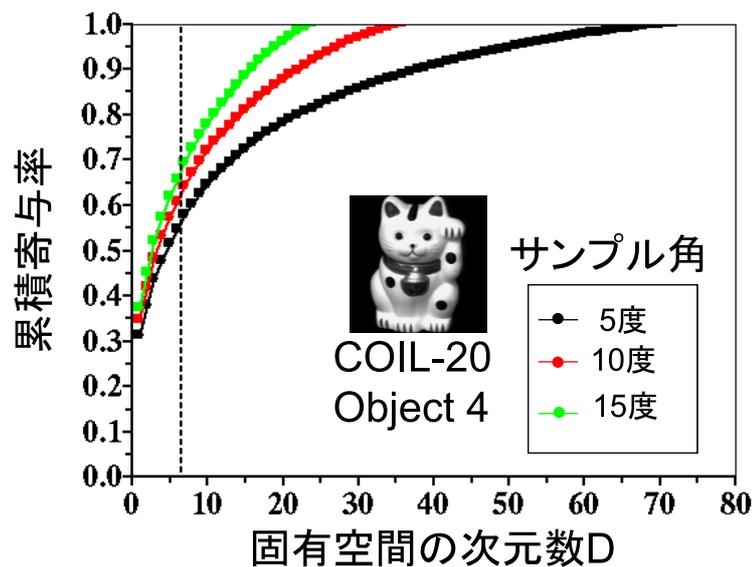


図 3.17: 次元変化による累積寄与率の変化 (COIL-20 obj4)

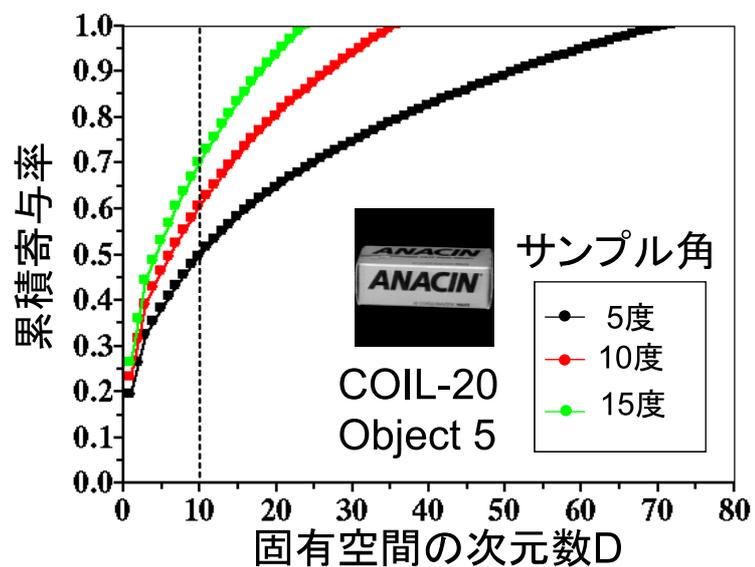


図 3.18: 次元変化による累積寄与率の変化 (COIL-20 obj5)

### 3.8 RMSE が 100 付近に収束する原因の検討

3.7 節まで, 学習条件を変えて精度変化の検討を行ってきた. その精度変化のグラフ (例えば, 図 3.16) を見ると, RMSE が 100 付近で収束しているように見える. そこで, RMSE の最大値について考えてみる. 式 (3.6) を二乗すると,

$$RMSE^2 = \frac{1}{72} \sum_{i=1}^{72} (\hat{\theta}_j - \theta_j)^2 \quad (3.8)$$

となる. RMSE が最大になる時が  $(\hat{\theta}_j - \theta_j)$  の確率変数が, 密度関数

$$f(x) = \begin{cases} \frac{1}{2\pi} & (-\pi \leq x \leq \pi) \\ 0 & (\text{その他}) \end{cases} \quad (3.9)$$

の一様分布に従う確率変数  $X (X \in [-\pi, \pi])$  になる時だと考えると, その期待値は,

$$E \left[ \frac{1}{72} \sum_{i=1}^{72} X^2 \right] = \frac{1}{72} \sum_{i=1}^{72} E[X^2] = E[X^2] \quad (3.10)$$

となる. この式を積分を用いて表し, 計算すると,

$$E[X^2] = \frac{1}{2\pi} \int_{-\pi}^{\pi} x^2 dx = \frac{1}{2\pi} \left[ \frac{1}{3} x^3 \right]_{-\pi}^{\pi} = \frac{\pi^2}{3} \quad (3.11)$$

となる. この期待値がもともと  $RMSE^2$  であったことから, 誤差の最大値は,

$$RMSE = \frac{\pi}{\sqrt{3}} \simeq 103[deg] \quad (3.12)$$

となる. このことより, 誤差が 100 付近に収束することが言える.



## 第4章 結論

今回、学習に基づく姿勢推定手法である EbC 法の、学習条件を変化させた検討を行った。まず、最初に行った、学習サンプル数変化では、学習する物体での精度変化の違いについて述べた。物体によっては、サンプル数の少ない場合より、多い場合の方が精度が悪くなる物体の存在を述べた。その原因を探るために、画像の特徴について検討を行った。その検討で、サンプル数の少ない場合より、多い場合の方が精度が悪くなる物体では、画像の相関が、対象画像付近とは離れた角度の画像で似た画像が存在することを述べ、その画像が共に学習されていないと、サンプル数がたとえ多くても精度が悪くなることを述べた。また、他の精度変化の検討として、固有空間の次元削減しての検討について述べた。この検討では、物体により、精度を保つのに最低限必要な次元数があることを述べた。この次元が、物体により違う原因を探ったが、まだわかっていない。

今後の課題は、固有空間の最低限必要な次元が、物体により違う原因を究明することが挙げられる。また、実際の 3 次元物体のパラメータは、3 自由度であることから、自由度を増やして検討を行うこと課題として挙げられる。また、この手法がどのくらい他の手法と精度が違うのか比較するために、他の手法との比較も今後の課題である。



## 第5章 謝辞

本研究を1年間行うにあたって、大変多くの方に御協力、ご配慮を頂きましたことを、まず心よりお礼申し上げます。ゼミでは様々な視点からの御質問、御指摘をして下さった広島大学大学院工学研究科情報工学専攻金田和文教授には大変感謝いたします。担当官として、日頃の御指導、研究に関する質問の丁寧な御返答をして頂いた、広島大学大学院工学研究科情報工学専攻玉木徹准教授には非常に感謝いたします。

また、本研究に対して、様々な御意見を頂いた、奈良先端科学技術大学院大学情報科学研究科天野敏之助教には大変感謝いたします。

また、名古屋工業大学木村将之氏には、同じEbC法を用いた研究を扱う大学院生として、結果や考察を参考にさせて頂き、大変感謝いたします。

また、本研究室の研究環境を整えて下さった広島大学大学院工学研究科情報工学専攻開内幸治技官には大変感謝いたします。本研究を行う上で、研究面でも生活面でも良きアドバイスをして頂いた本研究室の先輩方には大変感謝いたします。



## 参考文献

- [1] 天野敏之, 玉木徹 : Estimation-by-Completion : 3次元物体の線形姿勢推定手法, MIRU2006, pp.460-465.(2006)
- [2] 天野敏之, 玉木徹 : EbC 画像対を用いた三次元物体の高速線形姿勢推定, 電子情報通信学会論文誌 D, Vol.J90-D, No.8, pp.2060-2069 (2007 08).
- [3] 天野敏之, 佐藤幸男 : 固有空間を用いた BPLP による画像補間, 信学会論文誌 D- , Vol. J85-D , No. 3, pp. 457-465 (2002).
- [4] Toru Tamaki, Hiroyuki Okugawa, Toshiyuki Amano, Kazufumi Kaneda: "Experimental study on performance of view-based pose estimation" Proc. of FCV2008 ; the 14th Korea-Japan Joint Workshop on Frontiers of Computer Vision, pp.428-433 (2008 01).
- [5] S. A. Nene, S. K. Nayar, H. Murase:"Columbia Object Image Library (COIL-20)" ,Technical report CUUCS-005-96, Columbia University (1996).
- [6] S. A. Nene, S. K. Nayar, H. Murase,"Columbia Object Image Library (COIL-100)" ,Technical report CUUCS-006-96, Columbia University (1996).
- [7] 岩下友美, 倉爪亮, 小西晃造, 中本将彦, 橋爪誠, 長谷川勉, : 二次元距離場を用いた三次元幾何モデルと濃淡画像の高速な位置合せ, 信学会論文誌 D- , Vol. J88-D- ,No.9,pp.1889-1899,(2005).
- [8] 青井隆徳, 長橋宏 : 一般化円筒を用いた1枚のスケッチ画からの3次元モデリング, 信学会ソサイエティ大会講演論文集, p.415,(1996).
- [9] 石井健一郎, 上田修功, 前田栄作, 村瀬洋: わかりやすいパターン認識, オーム社,(1998).
- [10] 村瀬洋, シュリーナイヤー : 2次元照合による3次元物体認識 パラメトリック固有空間法 , 電子情報通信学会論文誌 DII, Vol. J77-D2, No. 11, pp. 2179-2187 (1994).



## 付録A COIL-20,COIL-100の 全物体 [5][6]

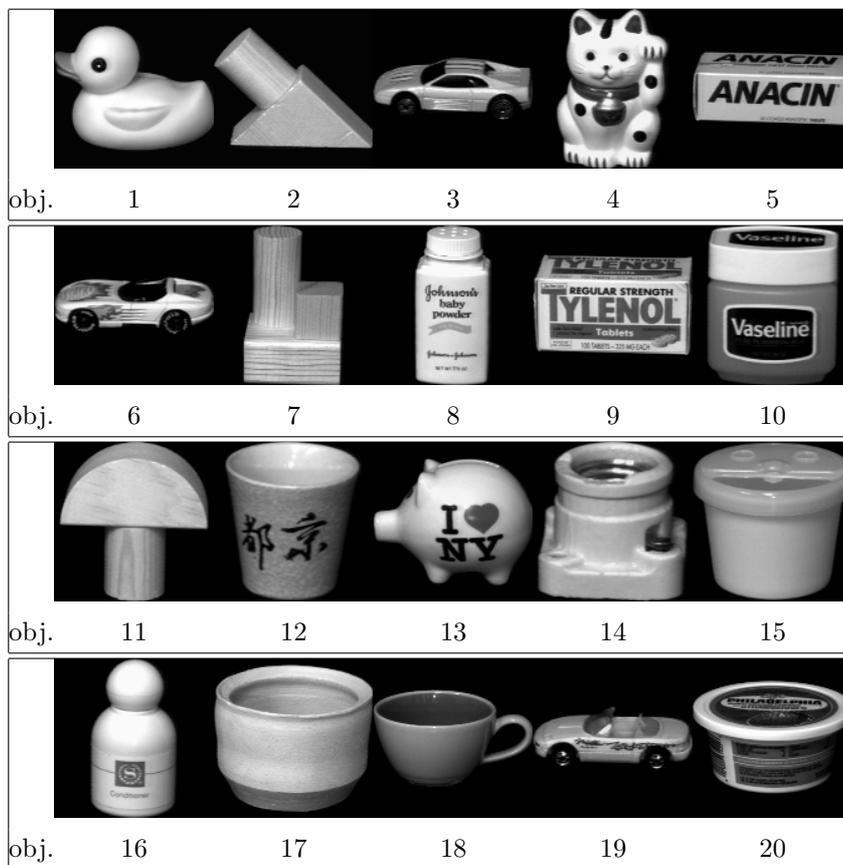


図 A.1: COIL-20 の全物体



図 A.2: COIL-100 の物体 (obj1-25)



図 A.3: COIL-100 の物体 (obj25-50)

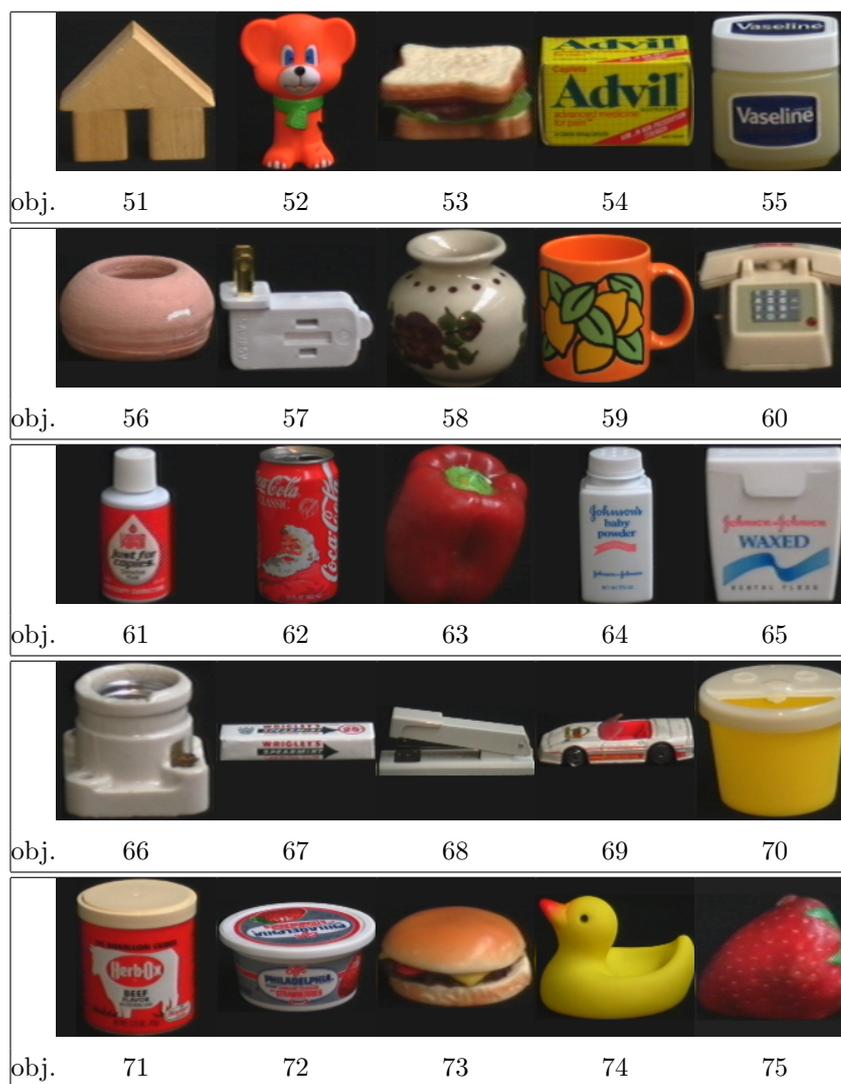


図 A.4: COIL-100 の物体 (obj51-75)



図 A.5: COIL-100 の物体 (obj76-100)



## 付録B 学習条件変化による検討 の全ての物体の結果

### B.1 学習サンプル数変化 (COIL-20)

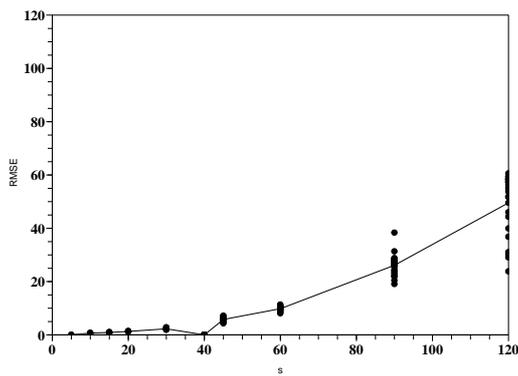


図 B.1.1: obj1

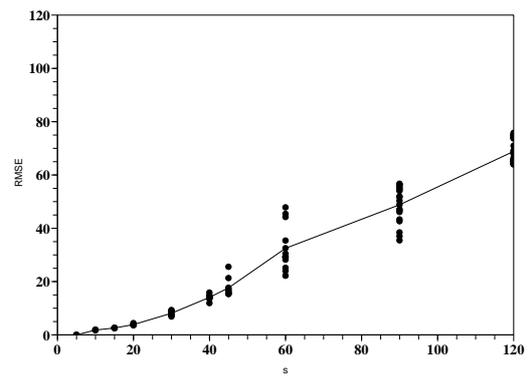


図 B.1.2: obj2

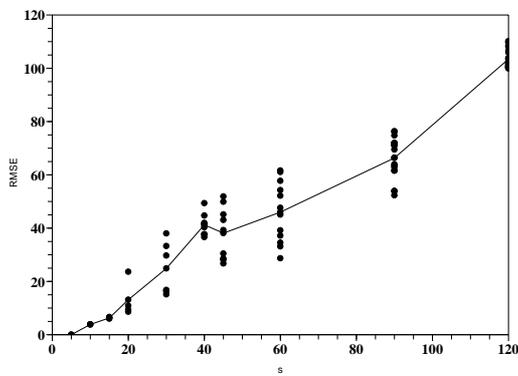


図 B.1.3: obj3

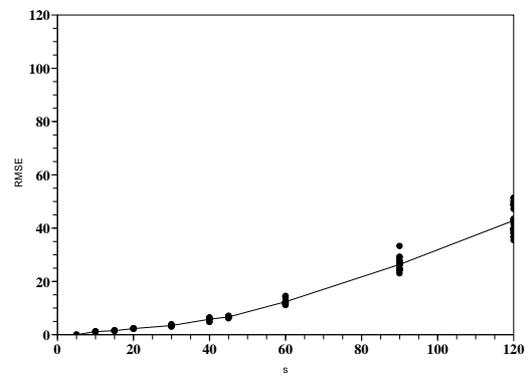


図 B.1.4: obj4

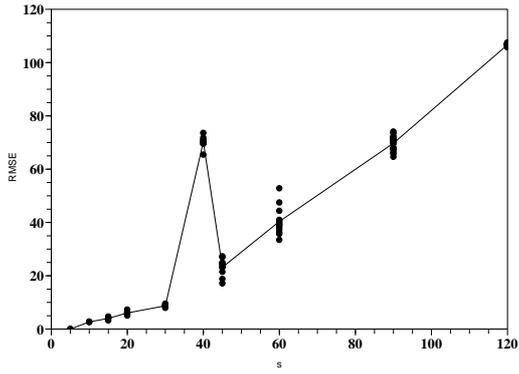


図 B.1.5: obj5

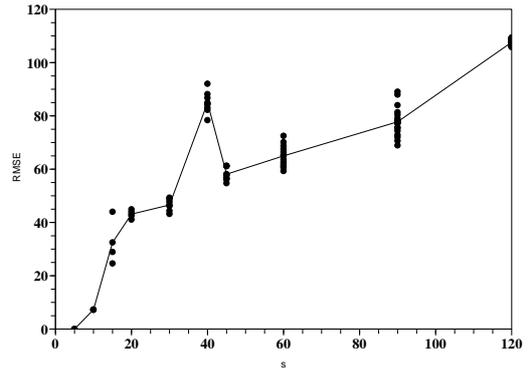


図 B.1.6: obj6

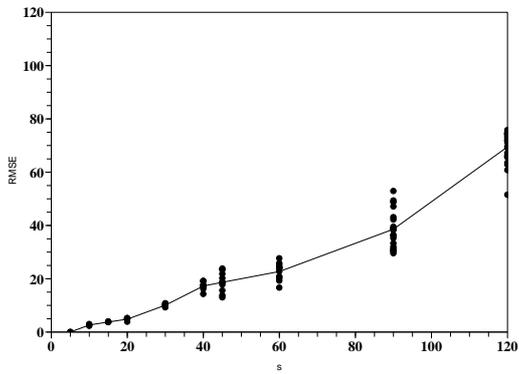


図 B.1.7: obj7

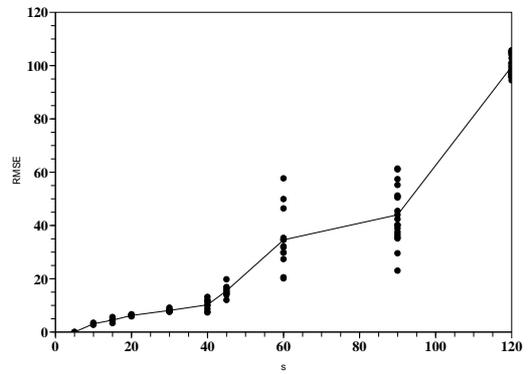


図 B.1.8: obj8

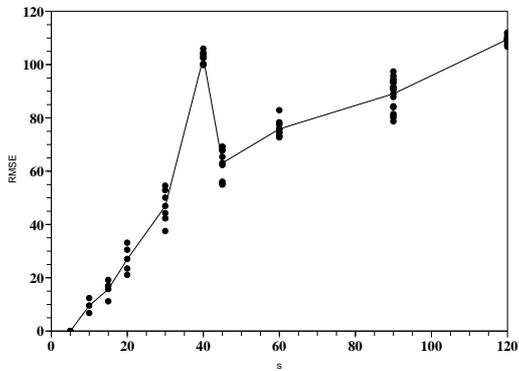


図 B.1.9: obj9

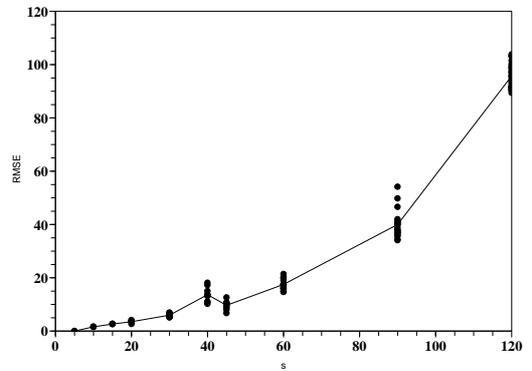


図 B.1.10: obj10

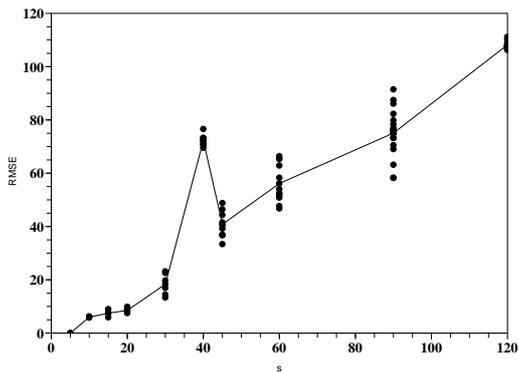


図 B.1.11: obj11

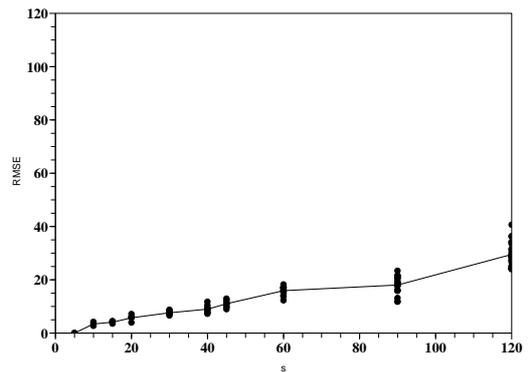
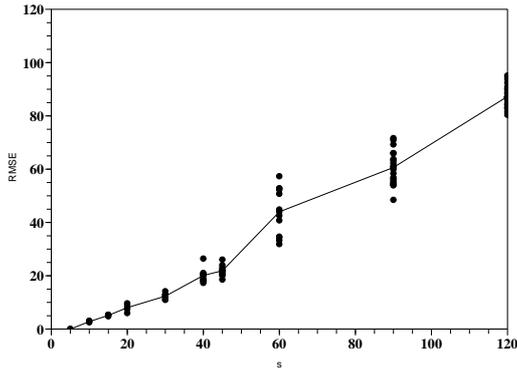
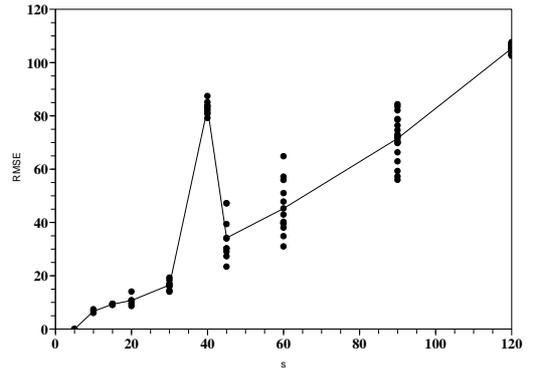


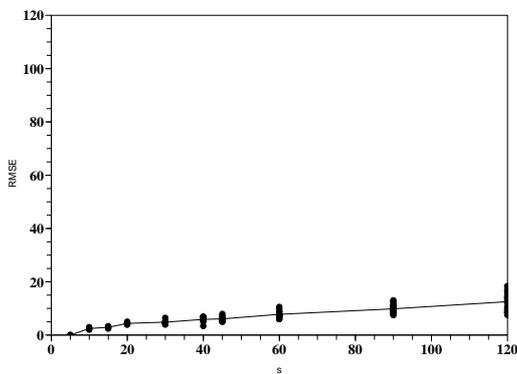
図 B.1.12: obj12



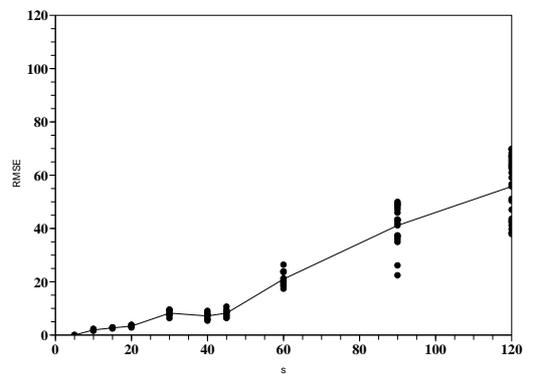
☒ B.1.13: obj13



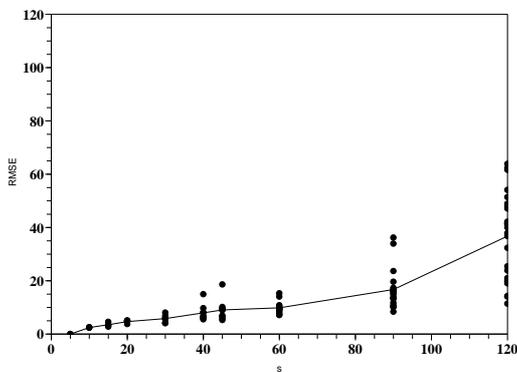
☒ B.1.14: obj14



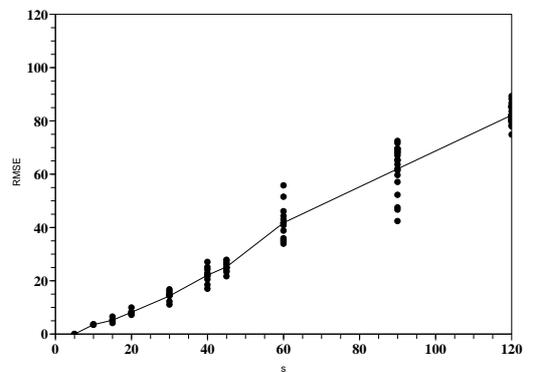
☒ B.1.15: obj15



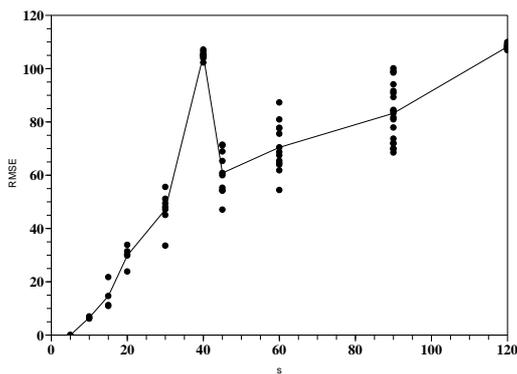
☒ B.1.16: obj16



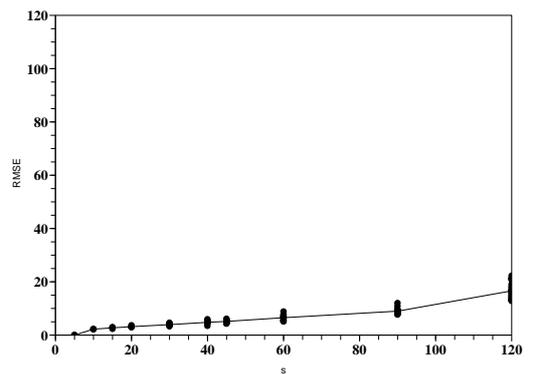
☒ B.1.17: obj17



☒ B.1.18: obj18



☒ B.1.19: obj19



☒ B.1.20: obj20

## B.2 学習サンプル数変化 (始点角0度 COIL-100)

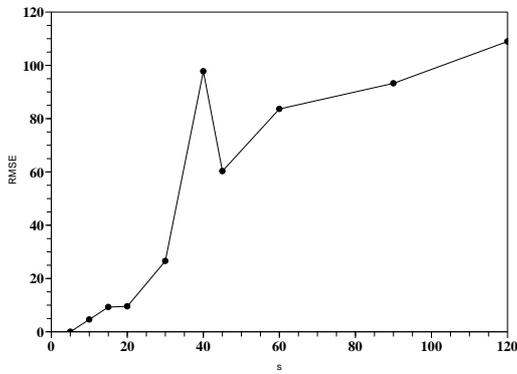


図 B.2.1: obj1

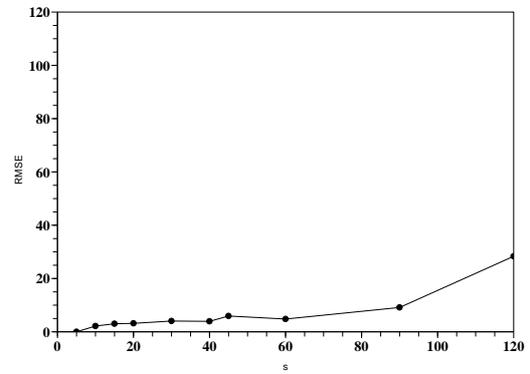


図 B.2.2: obj2

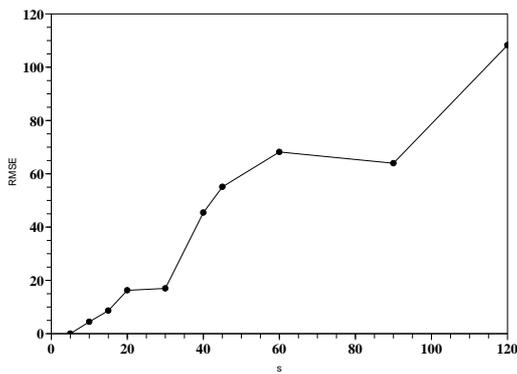


図 B.2.3: obj3

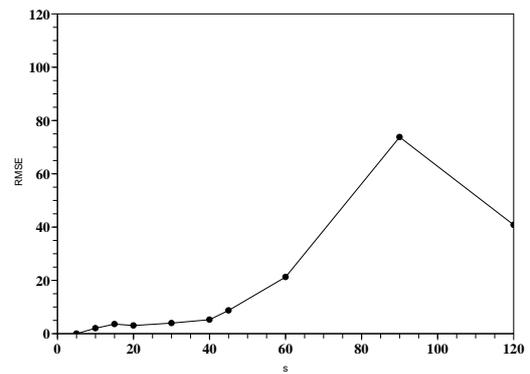


図 B.2.4: obj4

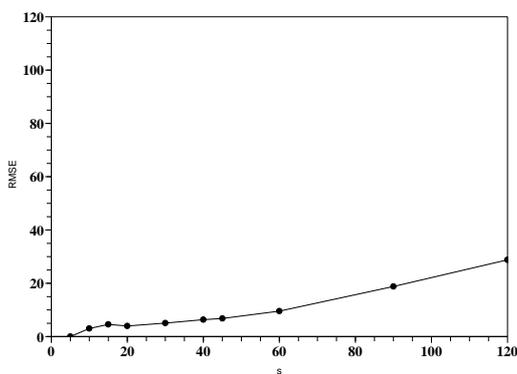


図 B.2.5: obj5

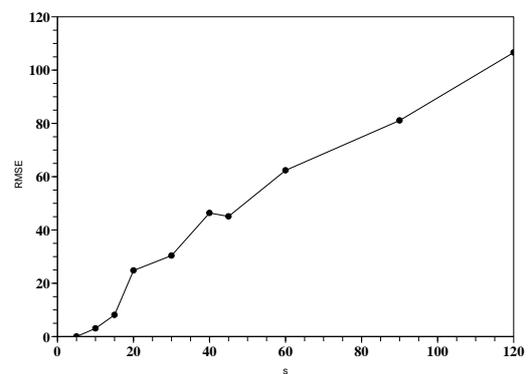
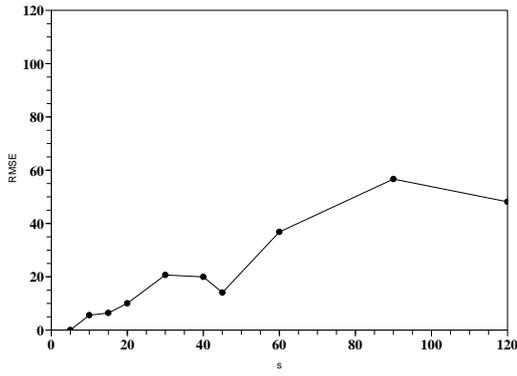
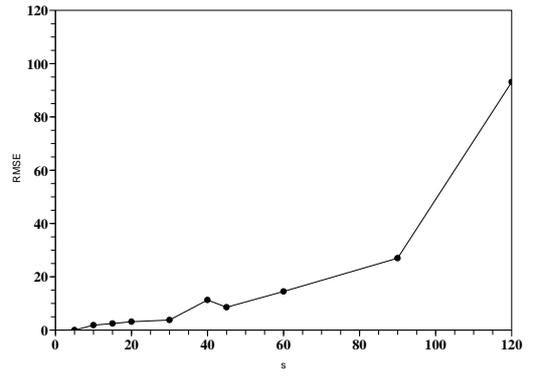


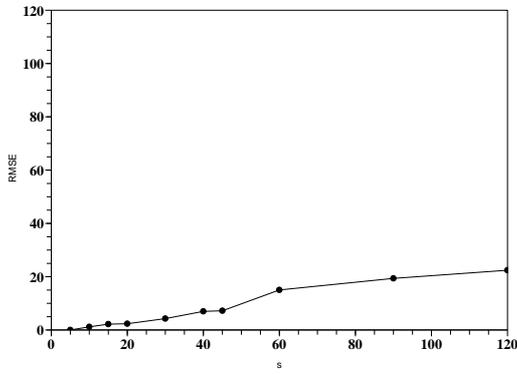
図 B.2.6: obj6



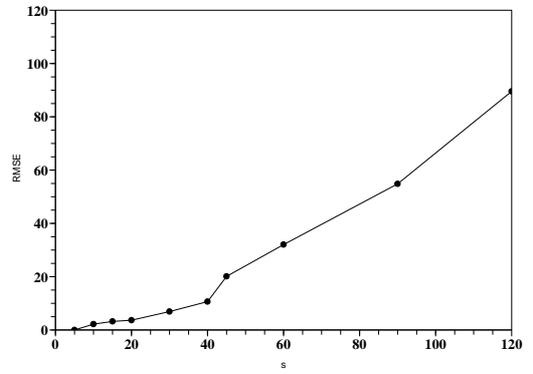
☒ B.2.7: obj7



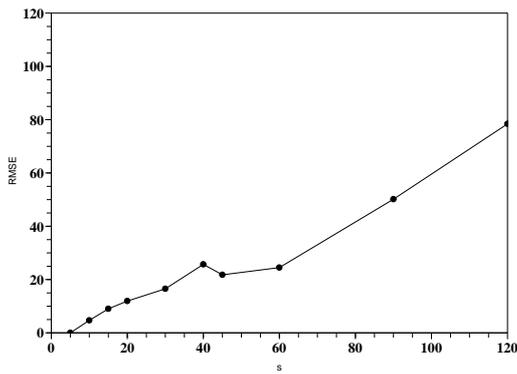
☒ B.2.8: obj8



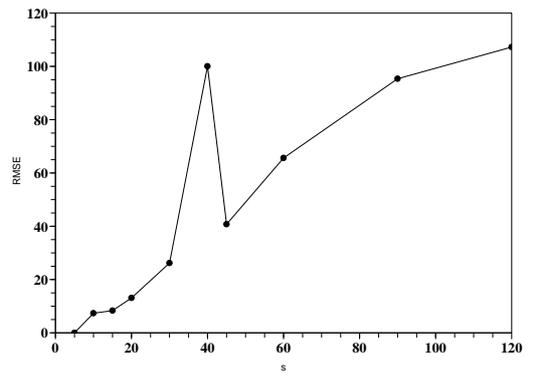
☒ B.2.9: obj9



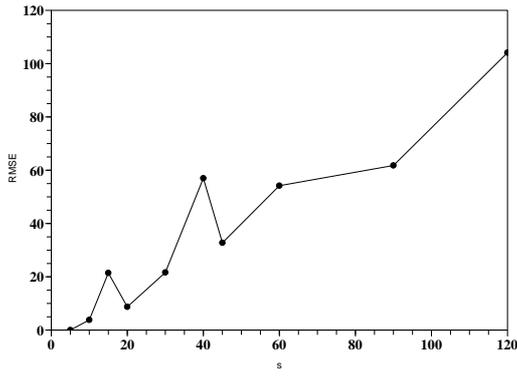
☒ B.2.10: obj10



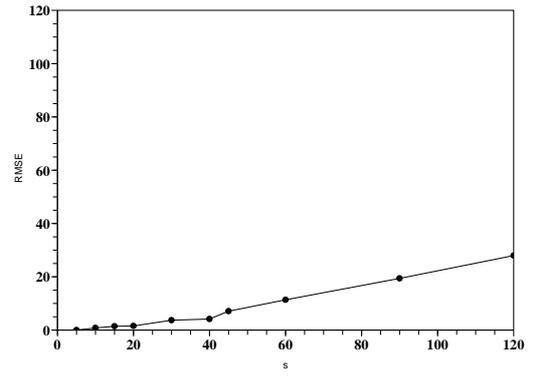
☒ B.2.11: obj11



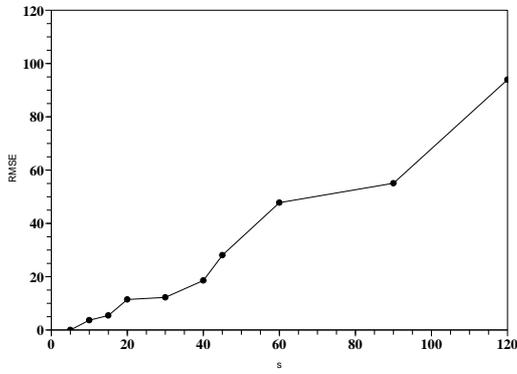
☒ B.2.12: obj12



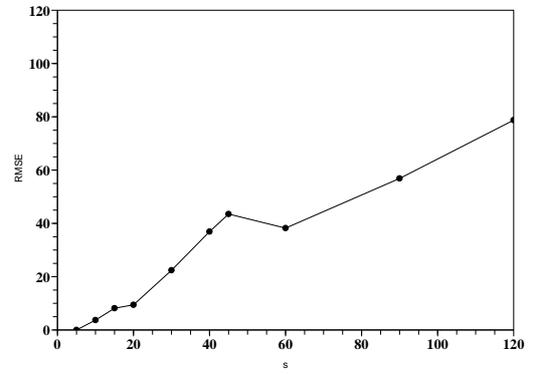
☒ B.2.13: obj13



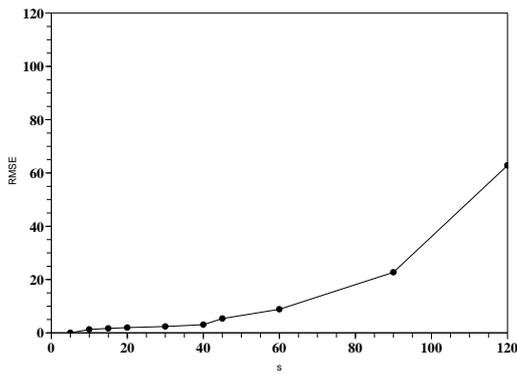
☒ B.2.14: obj14



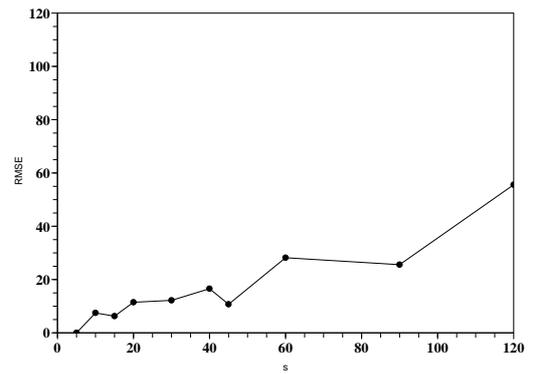
☒ B.2.15: obj15



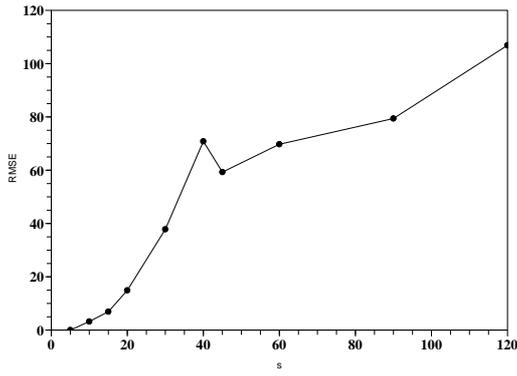
☒ B.2.16: obj16



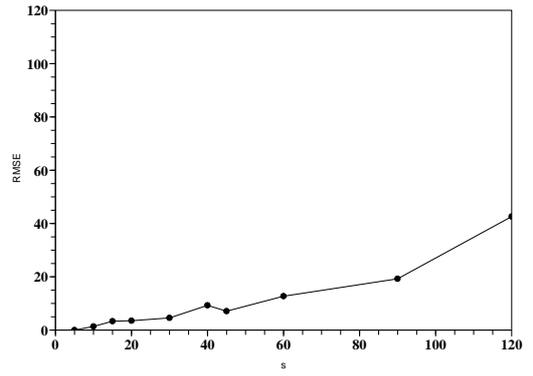
☒ B.2.17: obj17



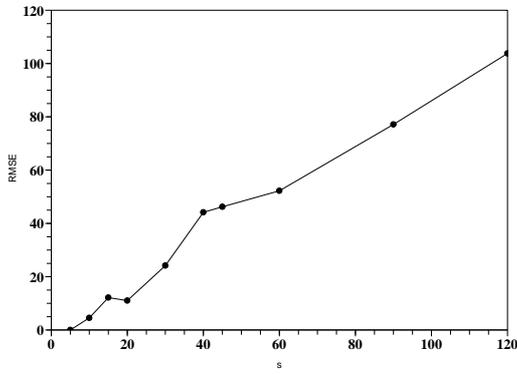
☒ B.2.18: obj18



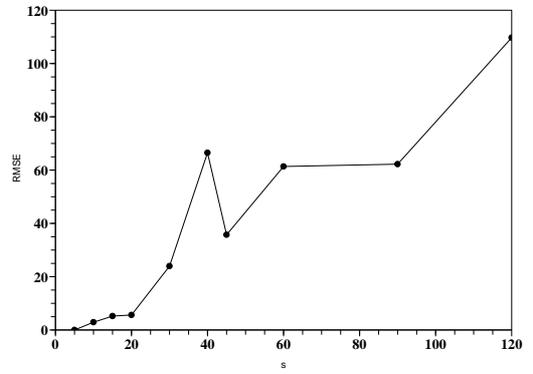
☒ B.2.19: obj19



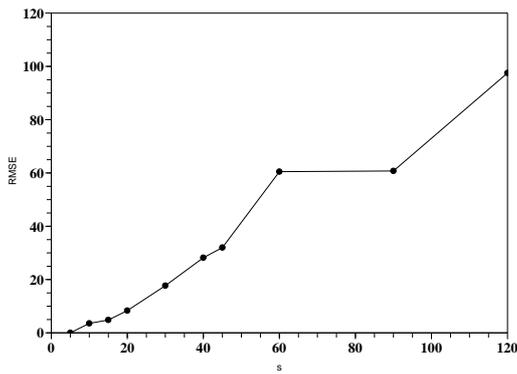
☒ B.2.20: obj20



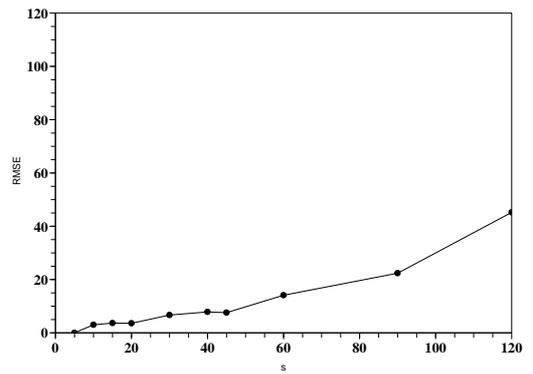
☒ B.2.21: obj21



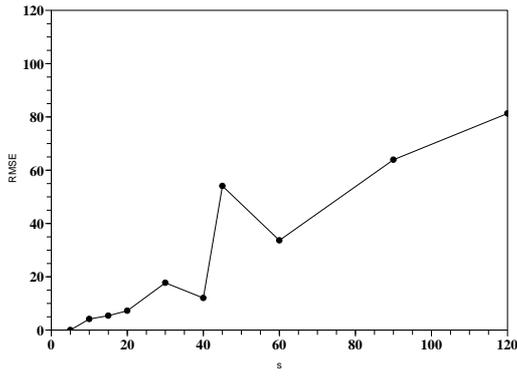
☒ B.2.22: obj22



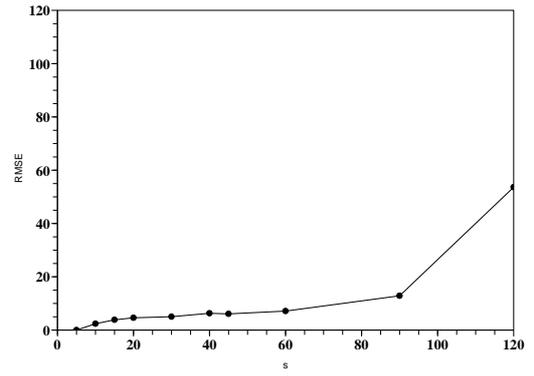
☒ B.2.23: obj23



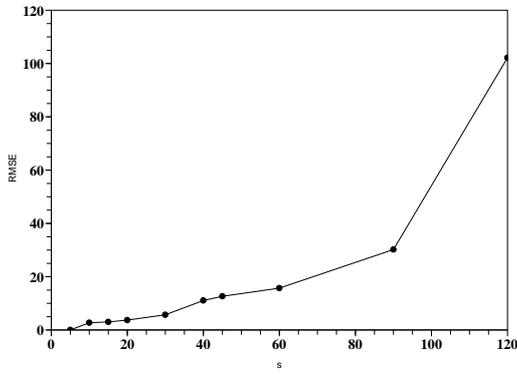
☒ B.2.24: obj24



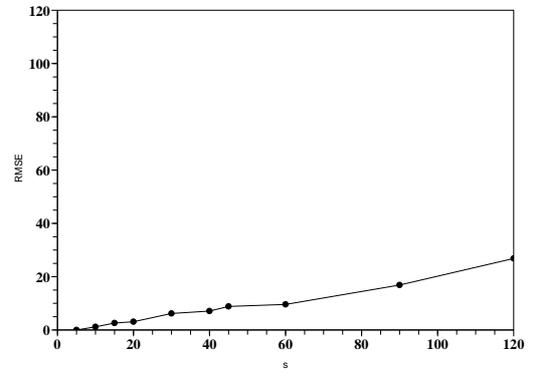
☒ B.2.25: obj25



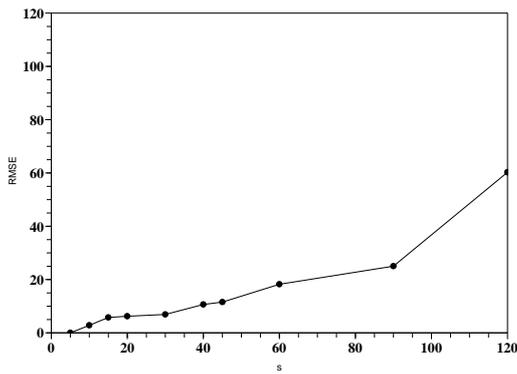
☒ B.2.26: obj26



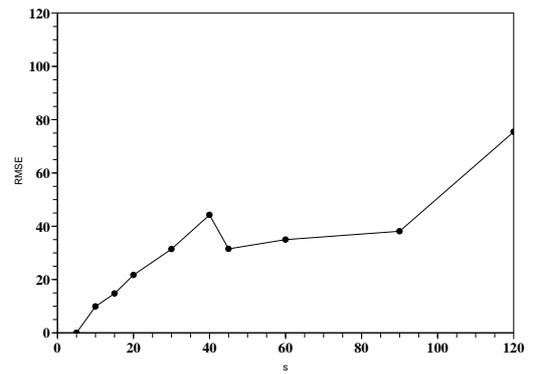
☒ B.2.27: obj27



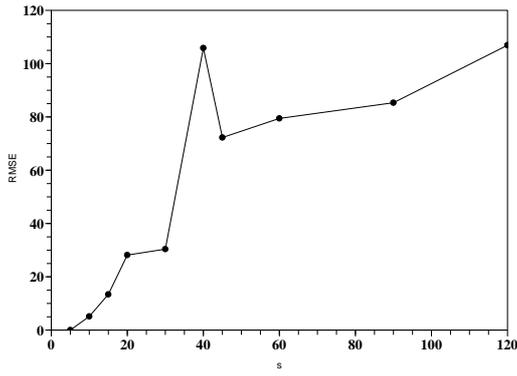
☒ B.2.28: obj28



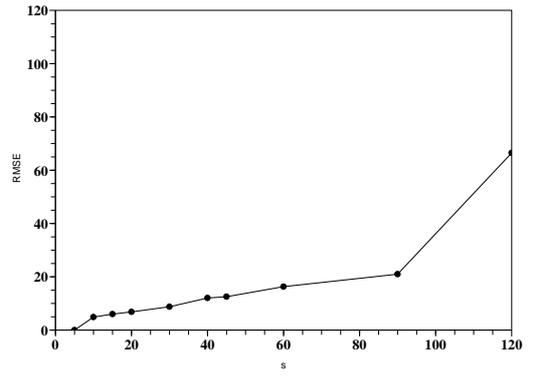
☒ B.2.29: obj29



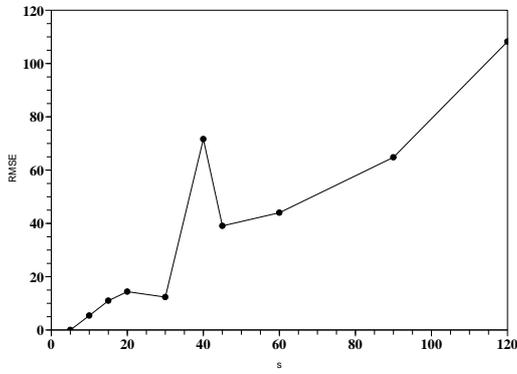
☒ B.2.30: obj30



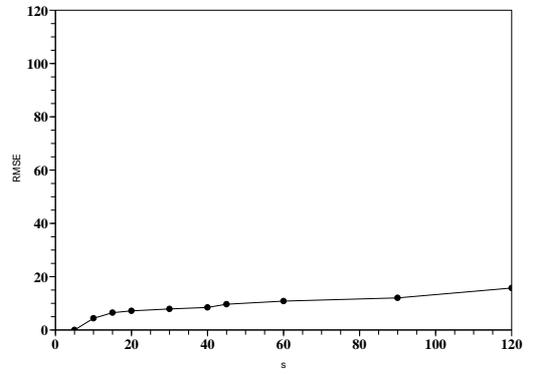
☒ B.2.31: obj31



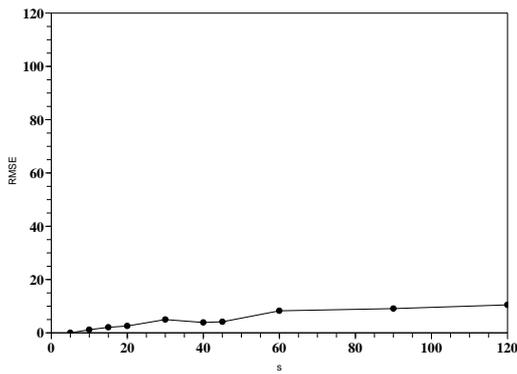
☒ B.2.32: obj32



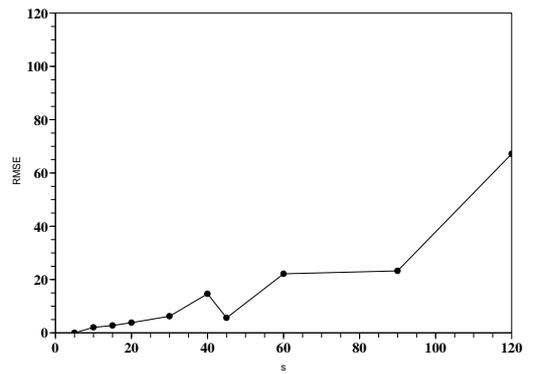
☒ B.2.33: obj33



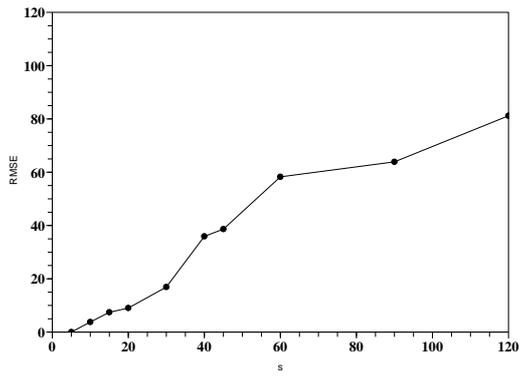
☒ B.2.34: obj34



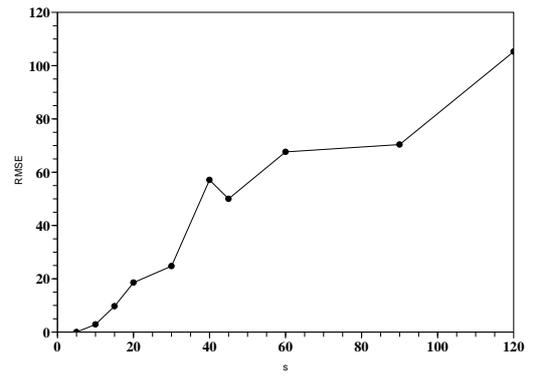
☒ B.2.35: obj35



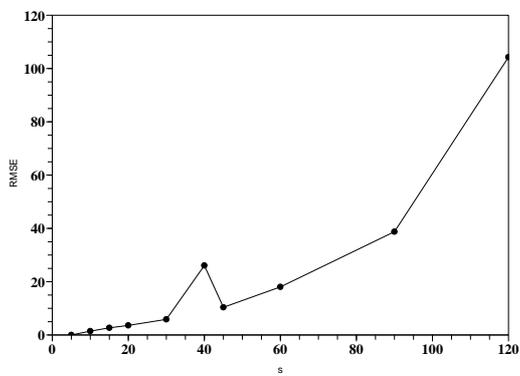
☒ B.2.36: obj36



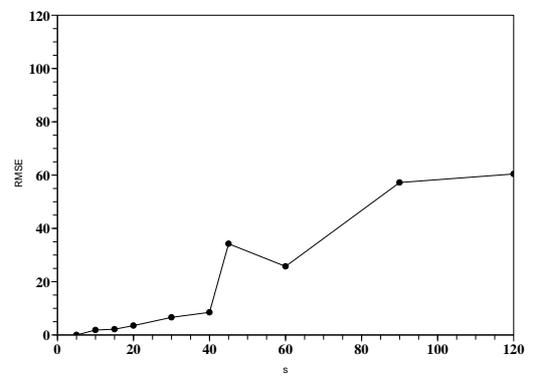
☒ B.2.37: obj37



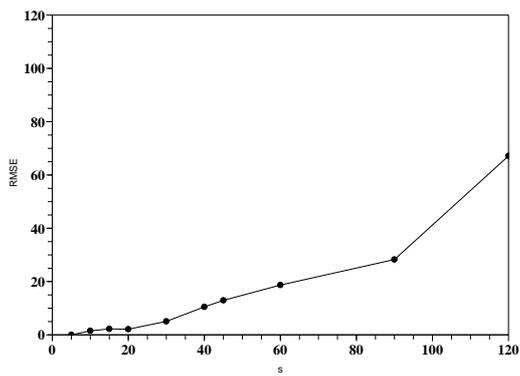
☒ B.2.38: obj38



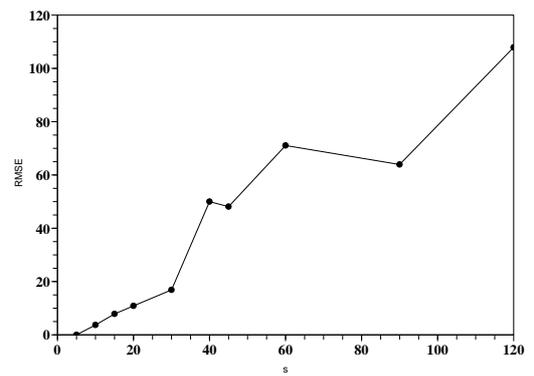
☒ B.2.39: obj39



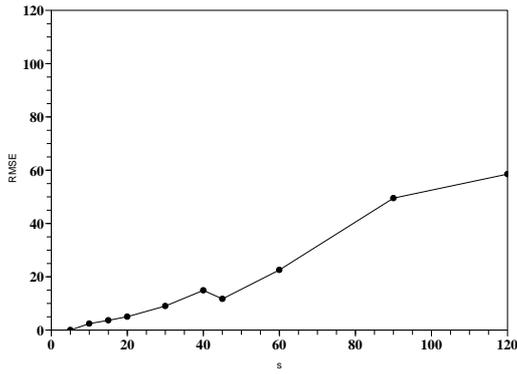
☒ B.2.40: obj40



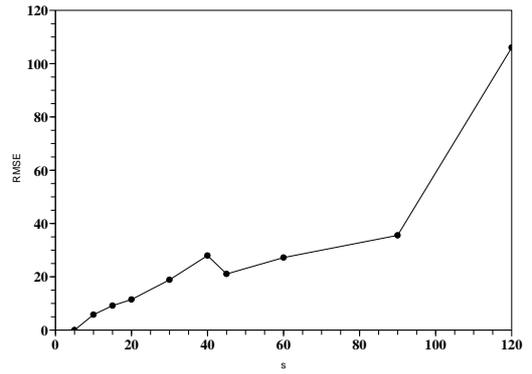
☒ B.2.41: obj41



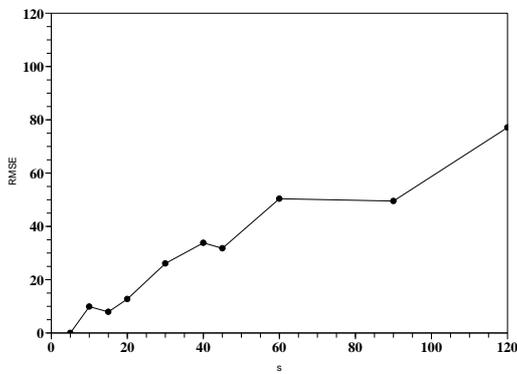
☒ B.2.42: obj42



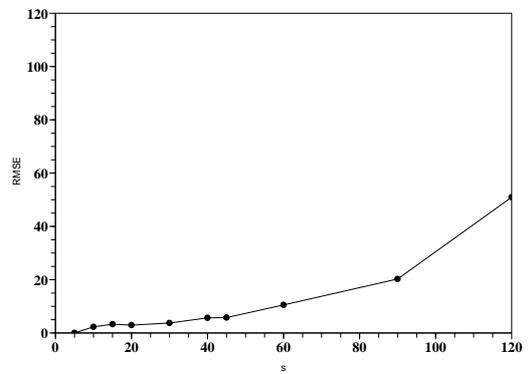
☒ B.2.43: obj43



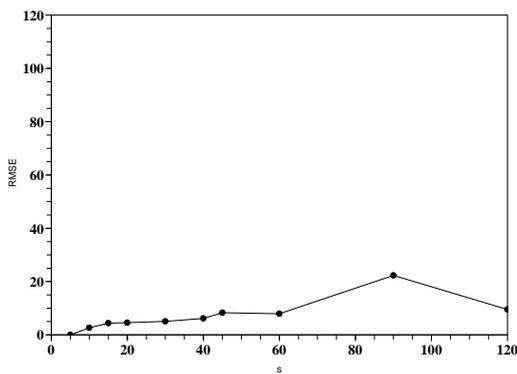
☒ B.2.44: obj44



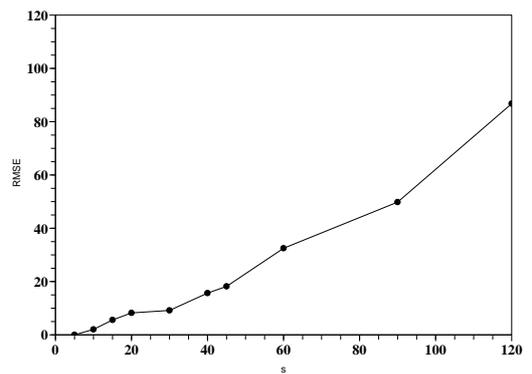
☒ B.2.45: obj45



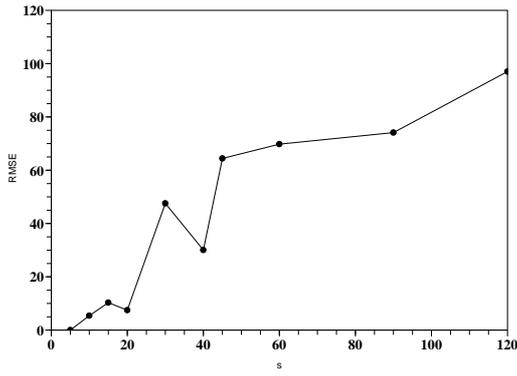
☒ B.2.46: obj46



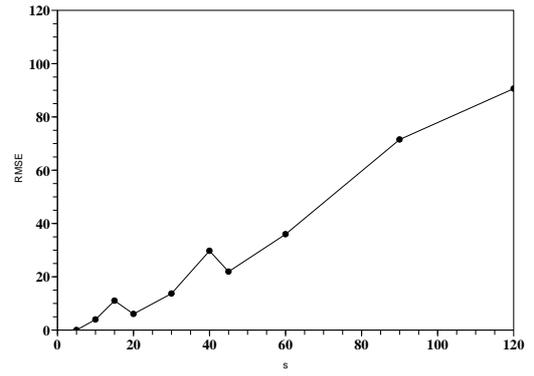
☒ B.2.47: obj47



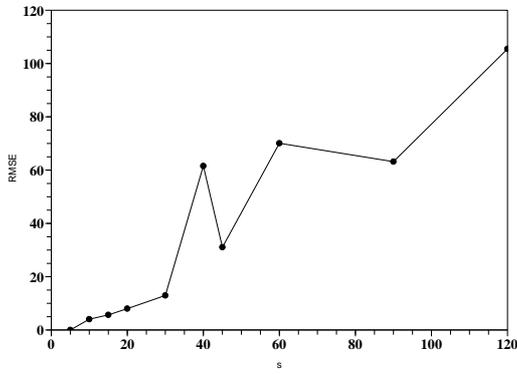
☒ B.2.48: obj48



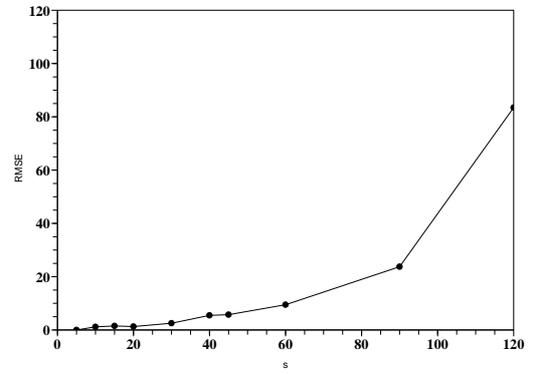
☒ B.2.49: obj49



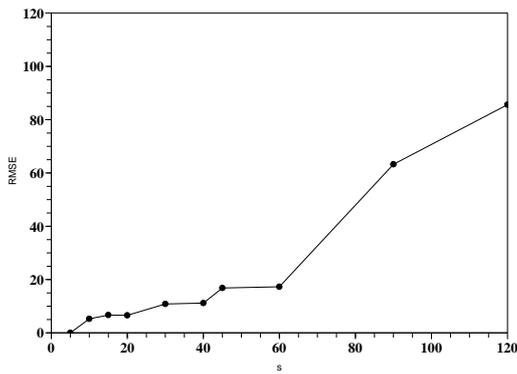
☒ B.2.50: obj50



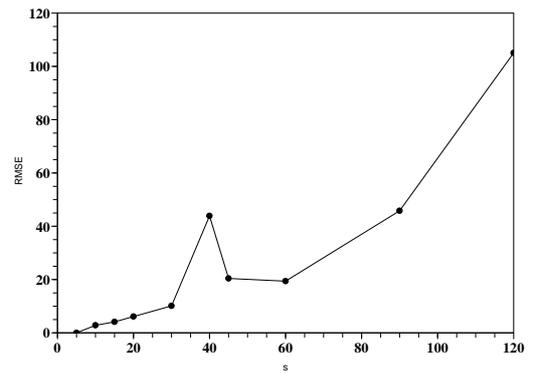
☒ B.2.51: obj51



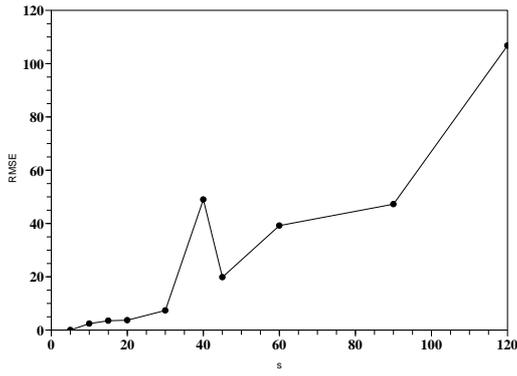
☒ B.2.52: obj52



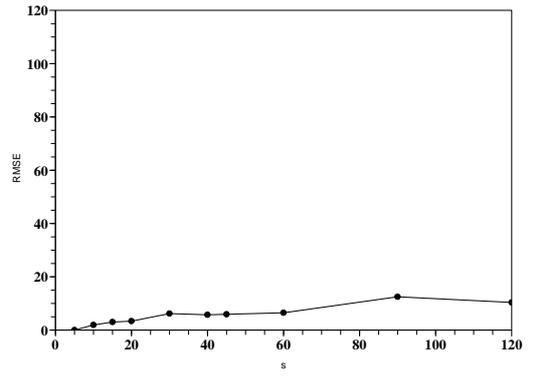
☒ B.2.53: obj53



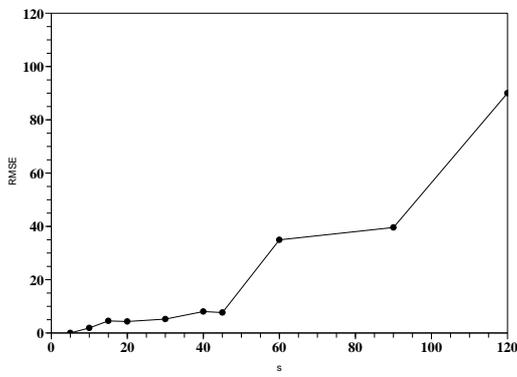
☒ B.2.54: obj54



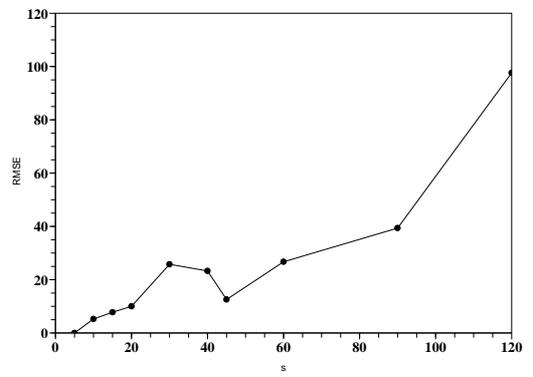
☒ B.2.55: obj55



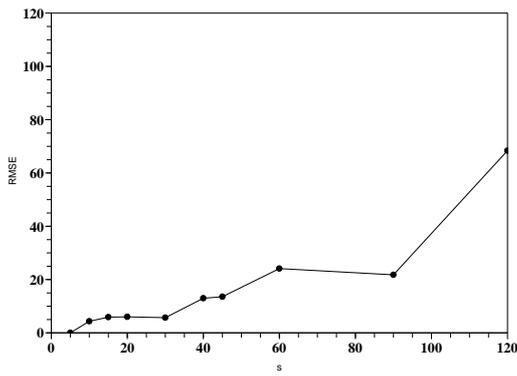
☒ B.2.56: obj56



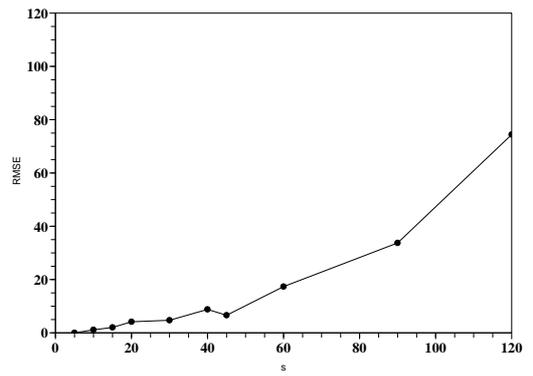
☒ B.2.57: obj57



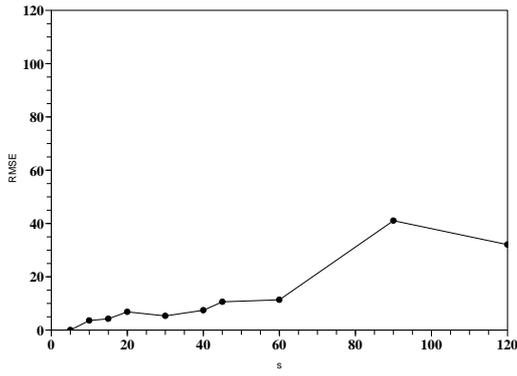
☒ B.2.58: obj58



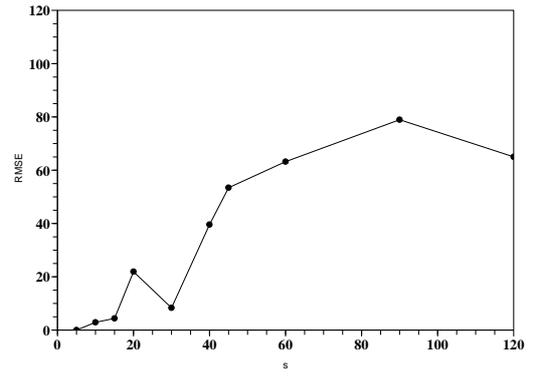
☒ B.2.59: obj59



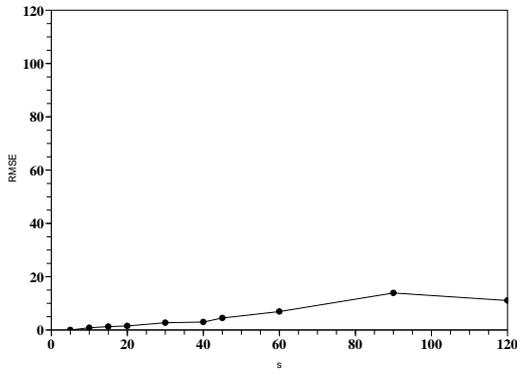
☒ B.2.60: obj60



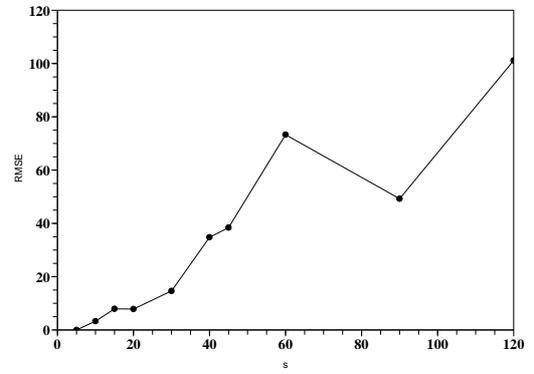
☒ B.2.61: obj61



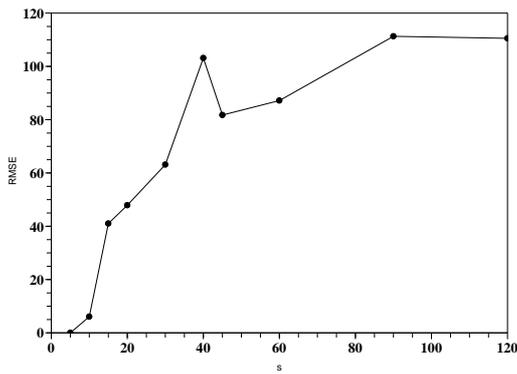
☒ B.2.62: obj62



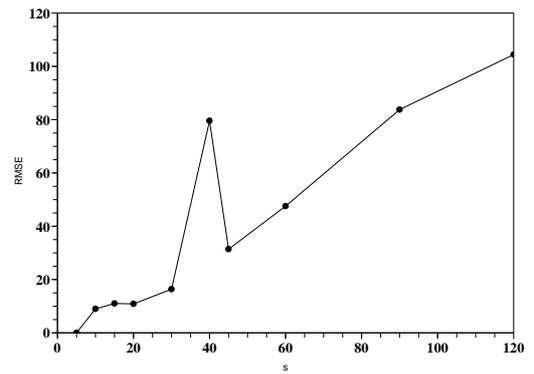
☒ B.2.63: obj63



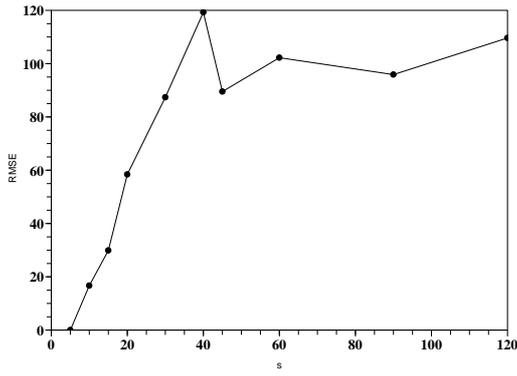
☒ B.2.64: obj64



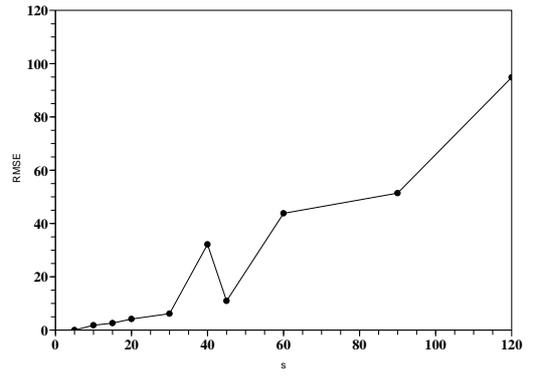
☒ B.2.65: obj65



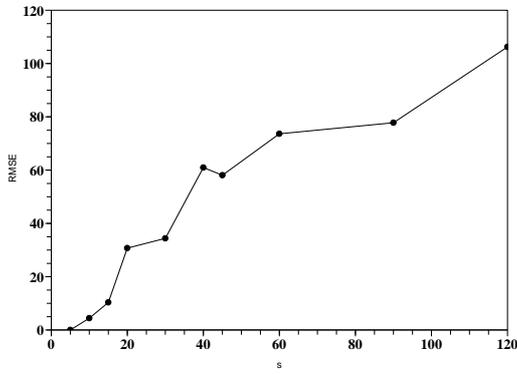
☒ B.2.66: obj66



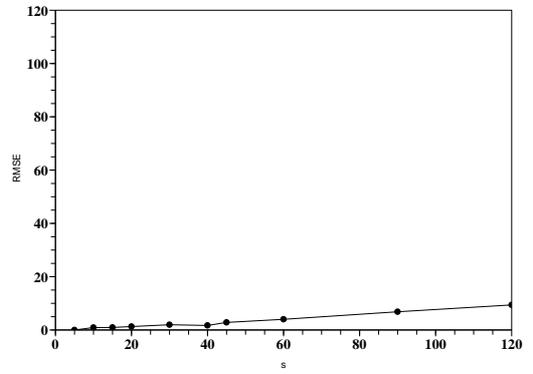
☒ B.2.67: obj67



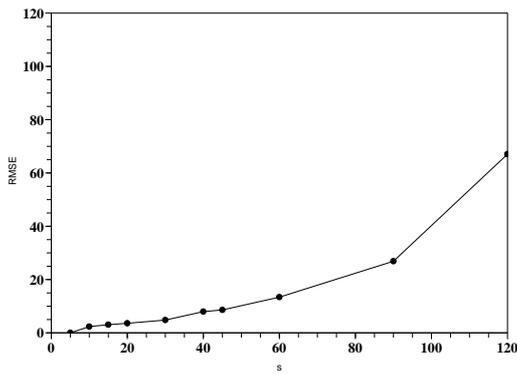
☒ B.2.68: obj68



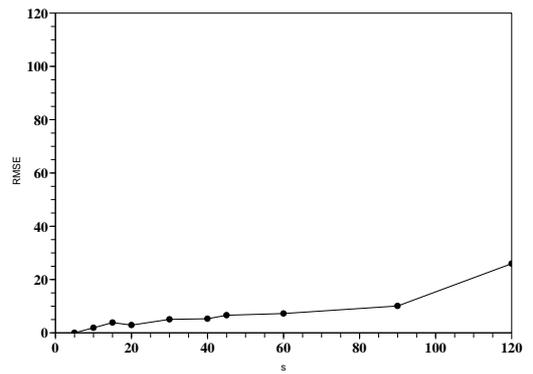
☒ B.2.69: obj69



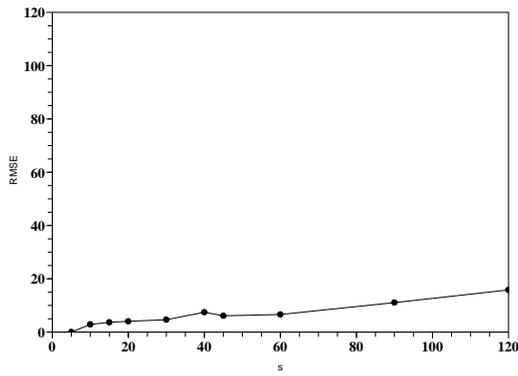
☒ B.2.70: obj70



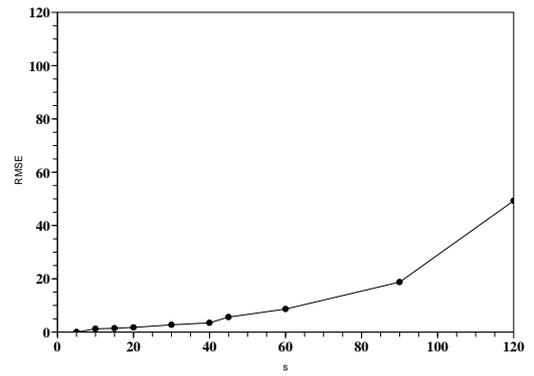
☒ B.2.71: obj71



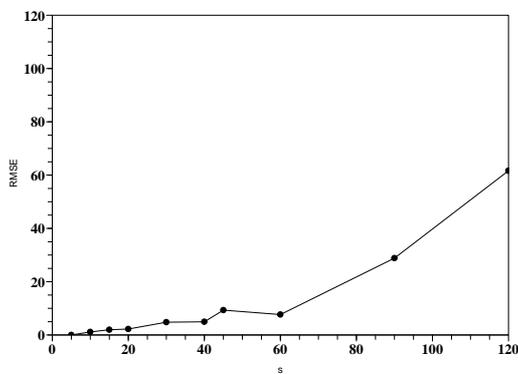
☒ B.2.72: obj72



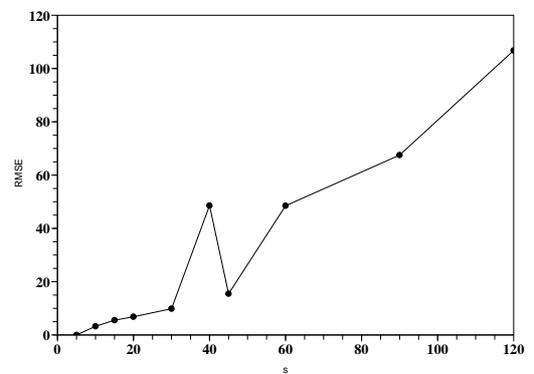
☒ B.2.73: obj73



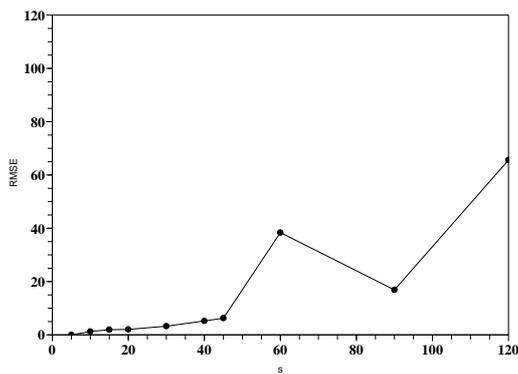
☒ B.2.74: obj74



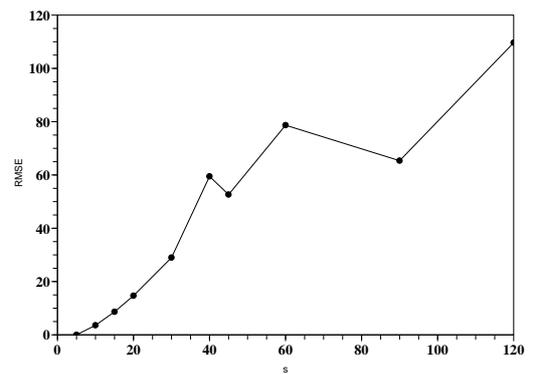
☒ B.2.75: obj75



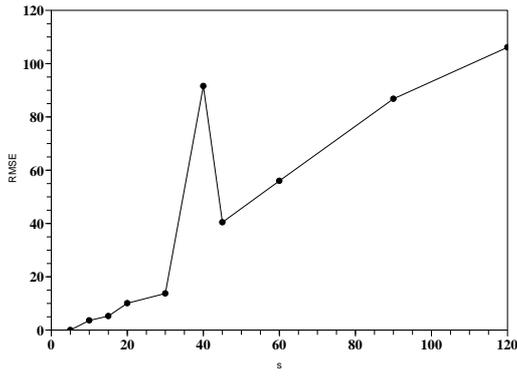
☒ B.2.76: obj76



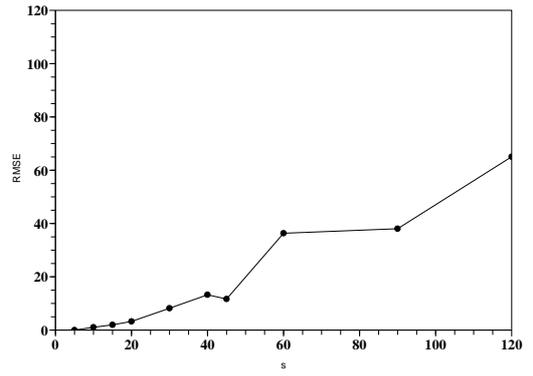
☒ B.2.77: obj77



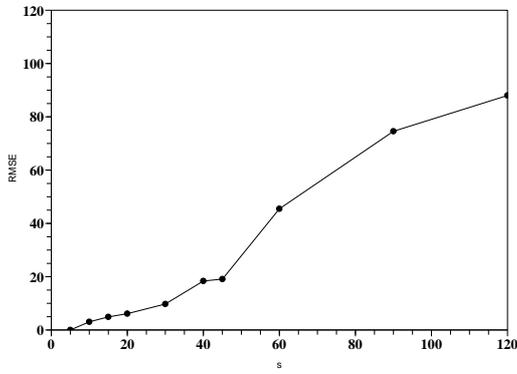
☒ B.2.78: obj78



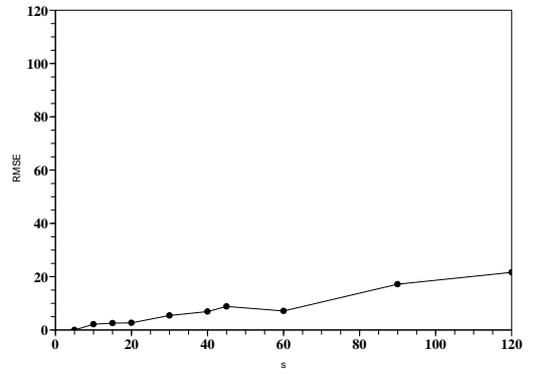
☒ B.2.79: obj79



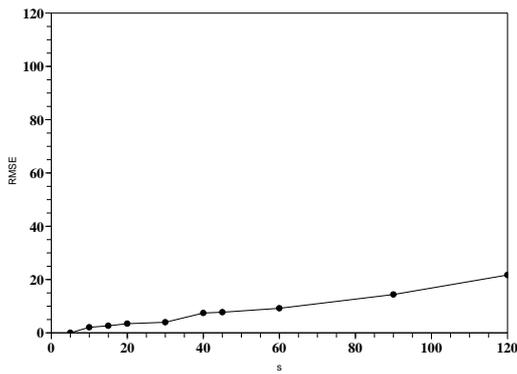
☒ B.2.80: obj80



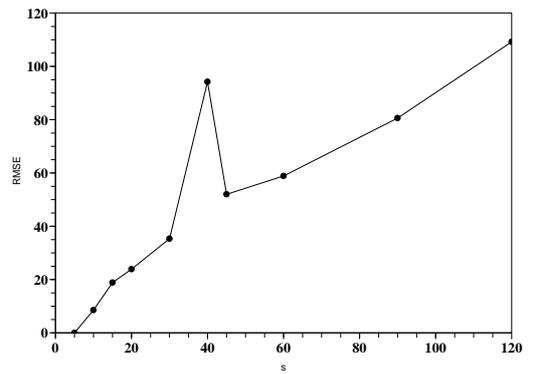
☒ B.2.81: obj81



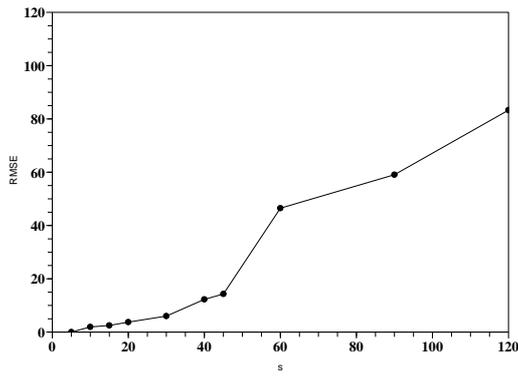
☒ B.2.82: obj82



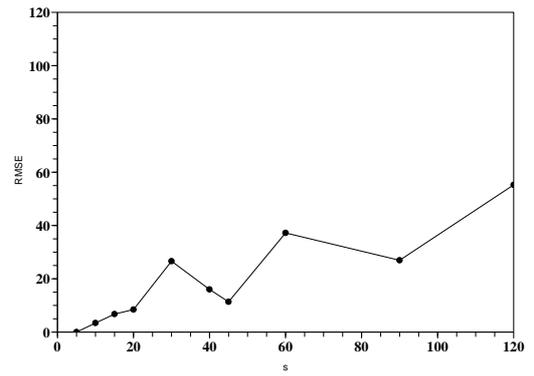
☒ B.2.83: obj83



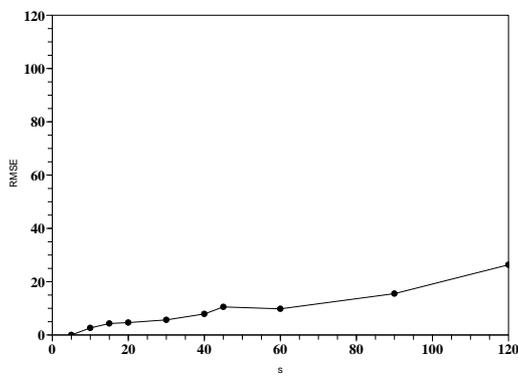
☒ B.2.84: obj84



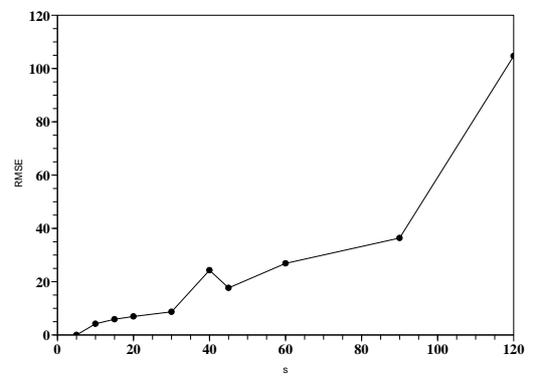
☒ B.2.85: obj85



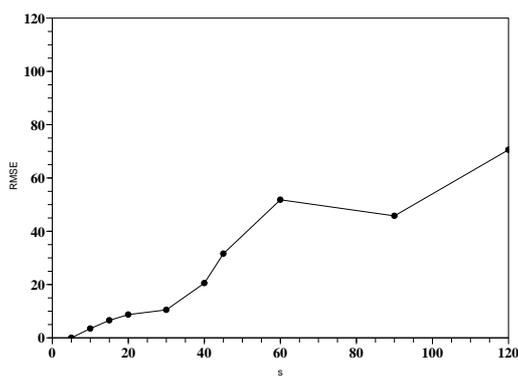
☒ B.2.86: obj86



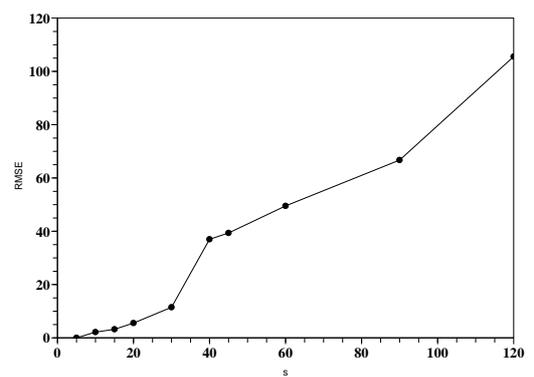
☒ B.2.87: obj87



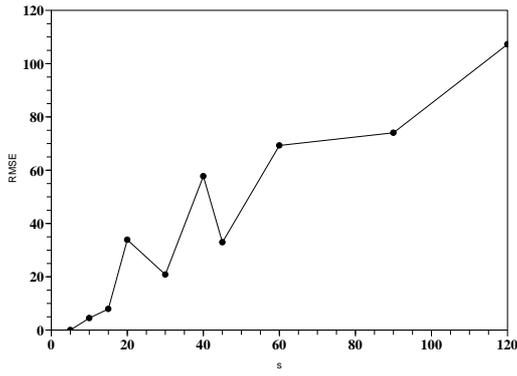
☒ B.2.88: obj88



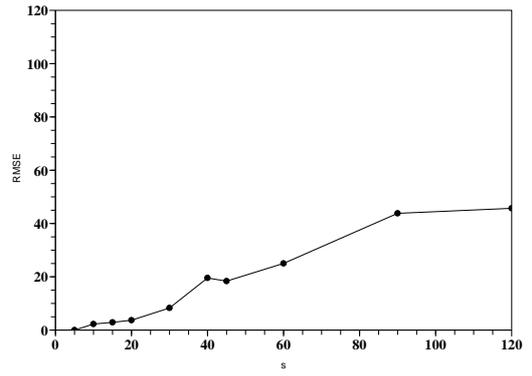
☒ B.2.89: obj89



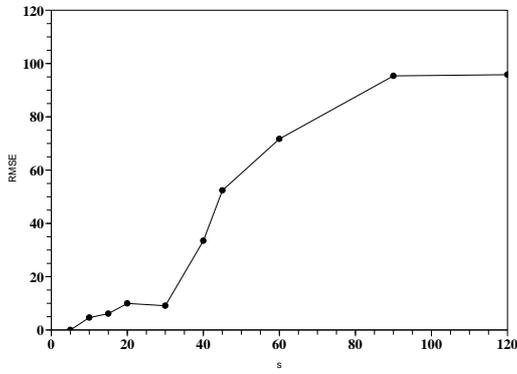
☒ B.2.90: obj90



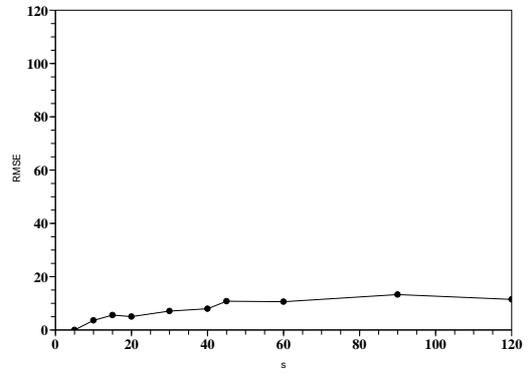
☒ B.2.91: obj91



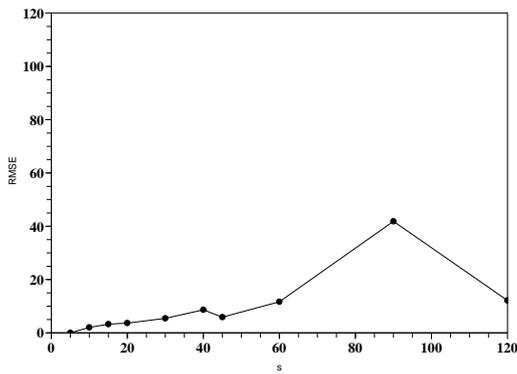
☒ B.2.92: obj92



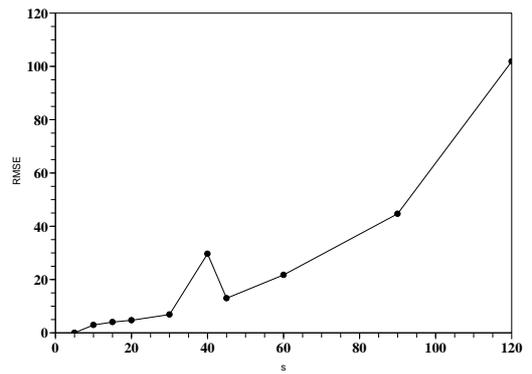
☒ B.2.93: obj93



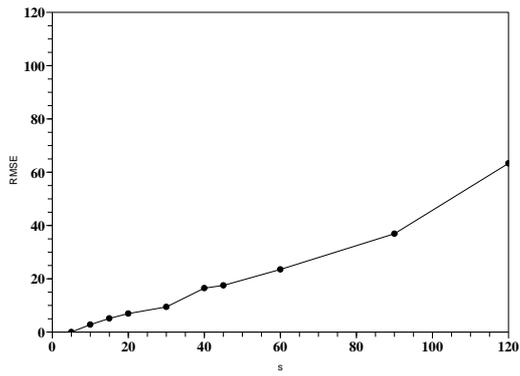
☒ B.2.94: obj94



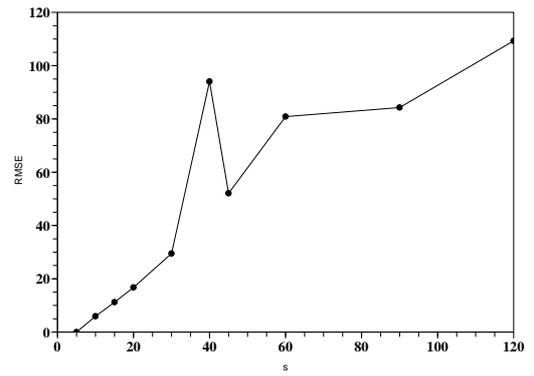
☒ B.2.95: obj95



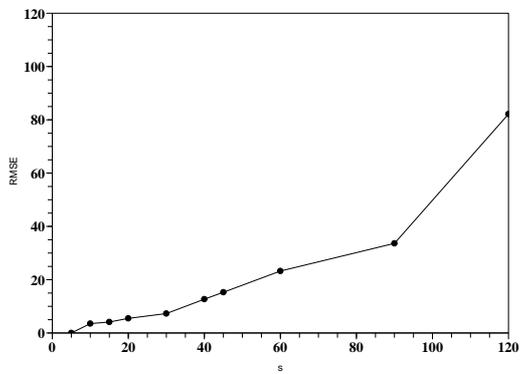
☒ B.2.96: obj96



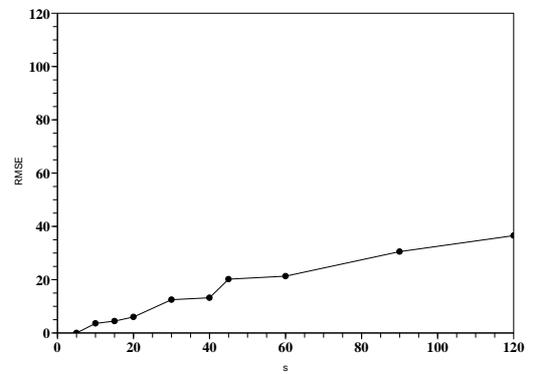
☒ B.2.97: obj97



☒ B.2.98: obj98

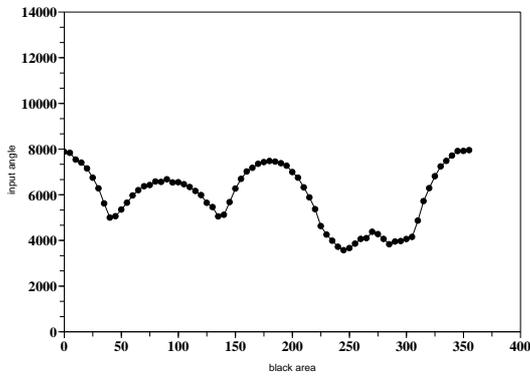


☒ B.2.99: obj99

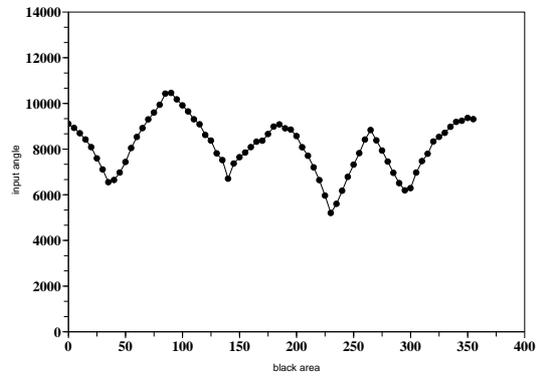


☒ B.2.100: obj100

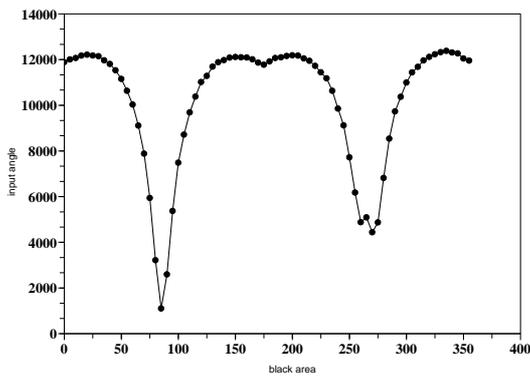
### B.3 背景の黒の面積変化 (COIL-20)



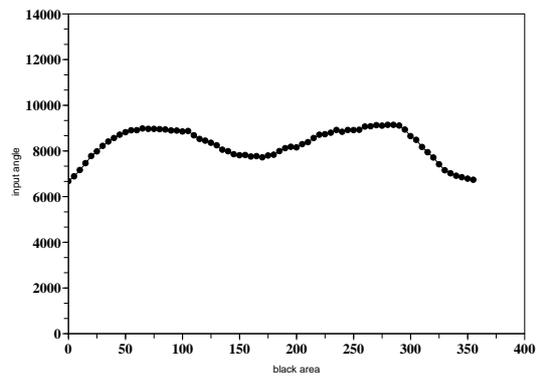
☒ B.3.1: obj1



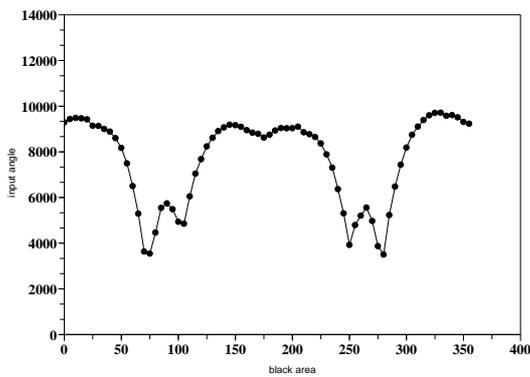
☒ B.3.2: obj2



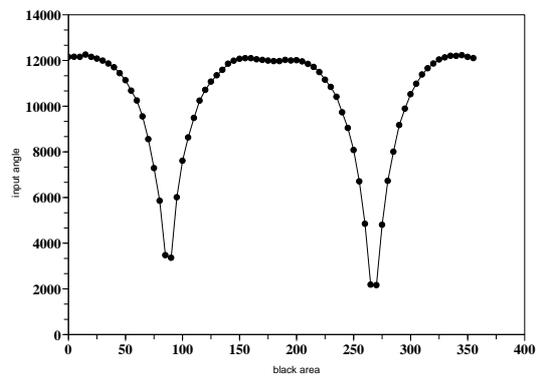
☒ B.3.3: obj3



☒ B.3.4: obj4



☒ B.3.5: obj5



☒ B.3.6: obj6

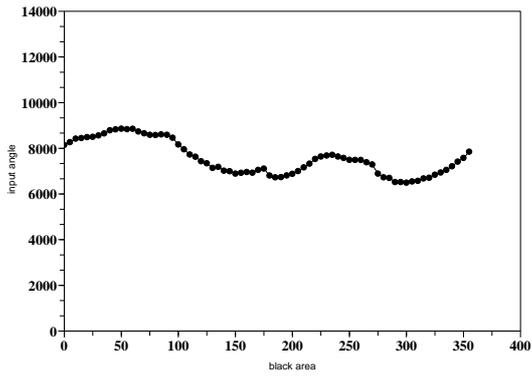


図 B.3.7: obj7

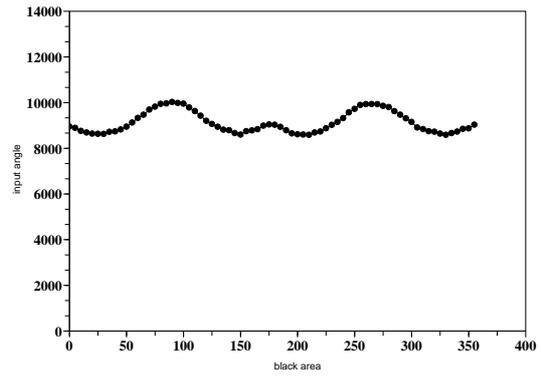


図 B.3.8: obj8

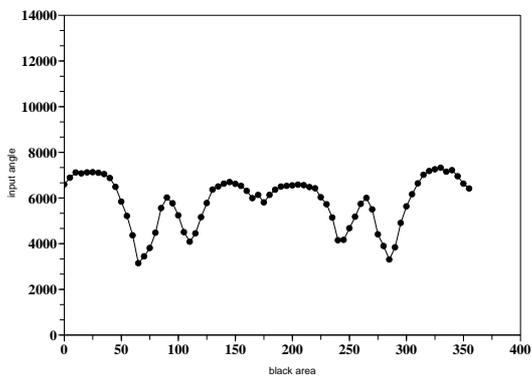


図 B.3.9: obj9

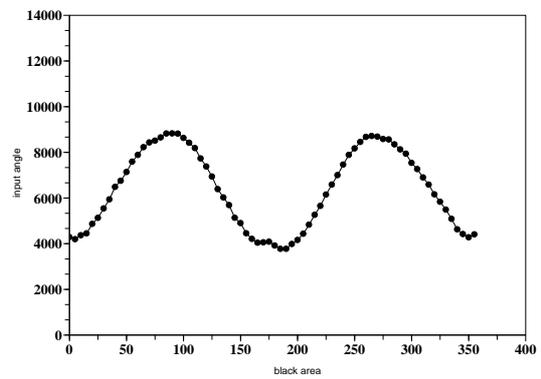


図 B.3.10: obj10

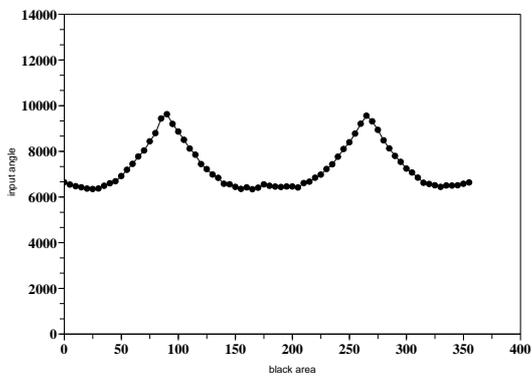


図 B.3.11: obj11

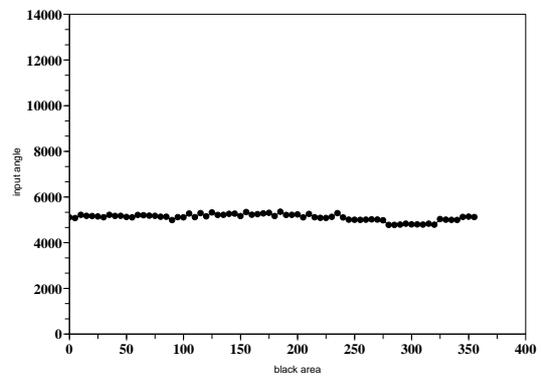


図 B.3.12: obj12

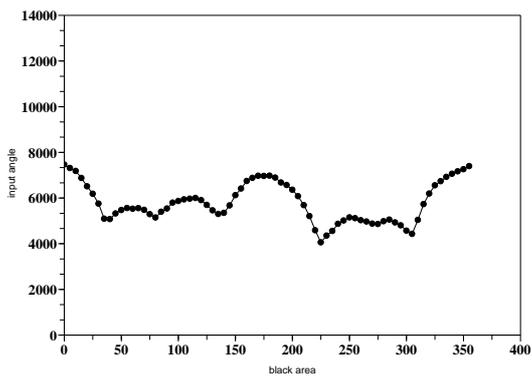


図 B.3.13: obj13

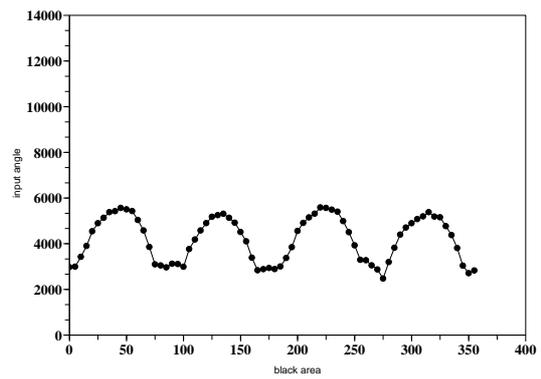


図 B.3.14: obj14

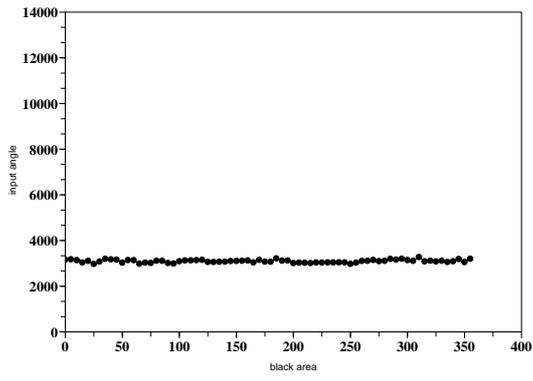


図 B.3.15: obj15

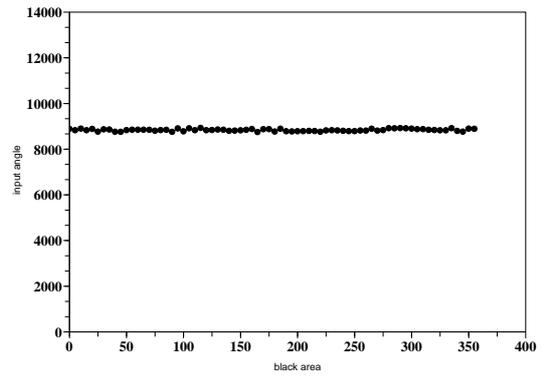


図 B.3.16: obj16

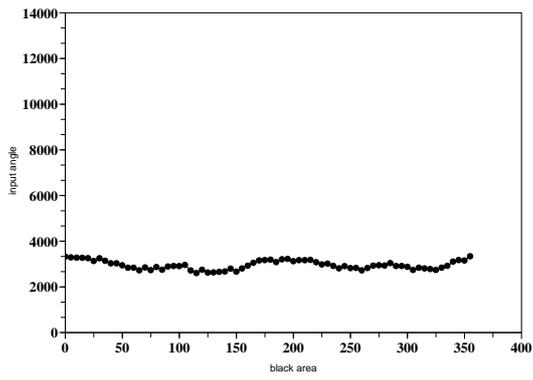


図 B.3.17: obj17

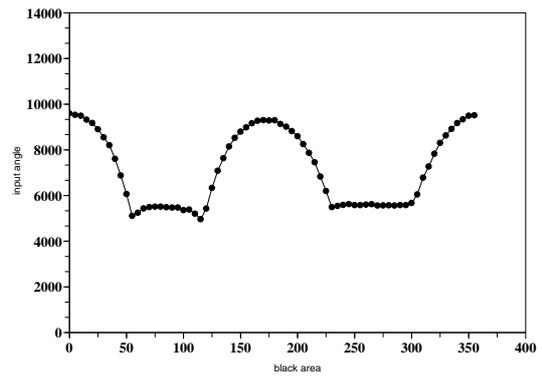


図 B.3.18: obj18

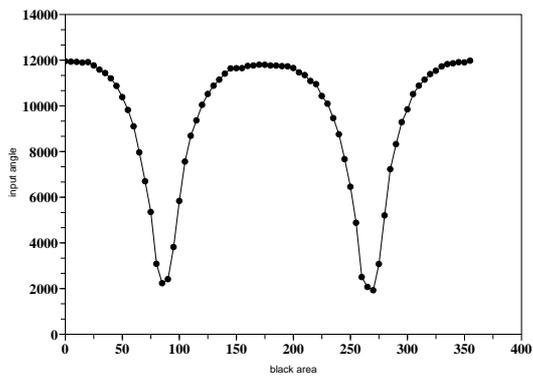


図 B.3.19: obj19

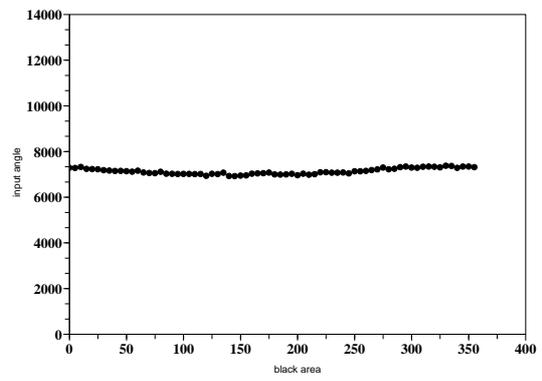


図 B.3.20: obj20

## B.4 背景の黒い面積の分散 (COIL-20)

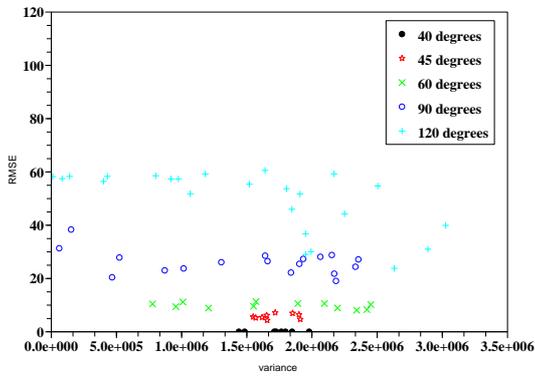


図 B.4.1: obj1

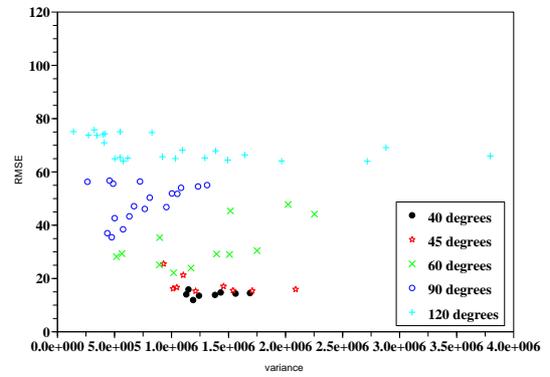


図 B.4.2: obj2

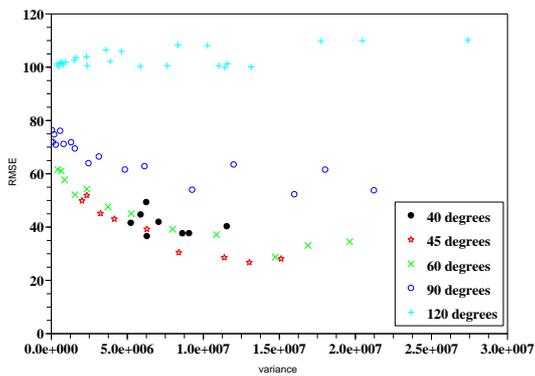


図 B.4.3: obj3

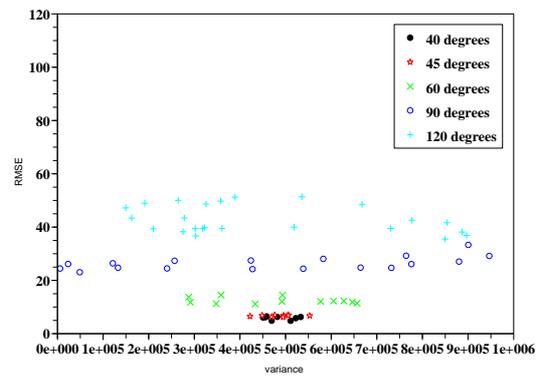


図 B.4.4: obj4

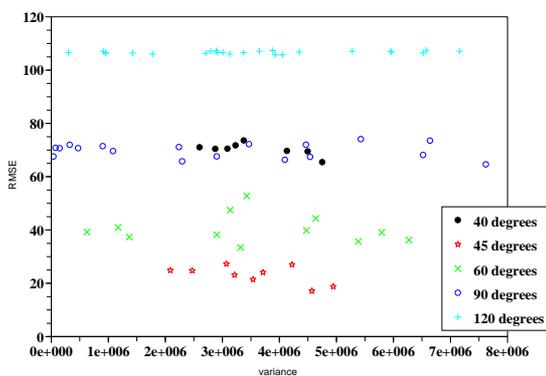


図 B.4.5: obj5

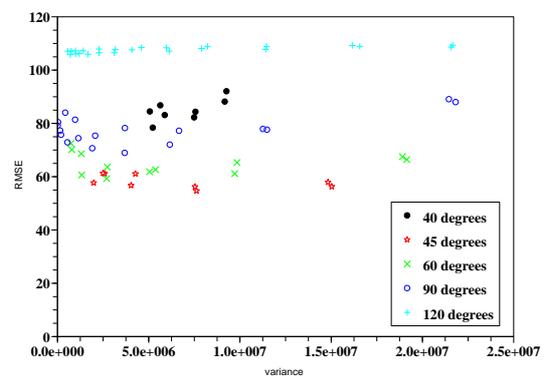


図 B.4.6: obj6

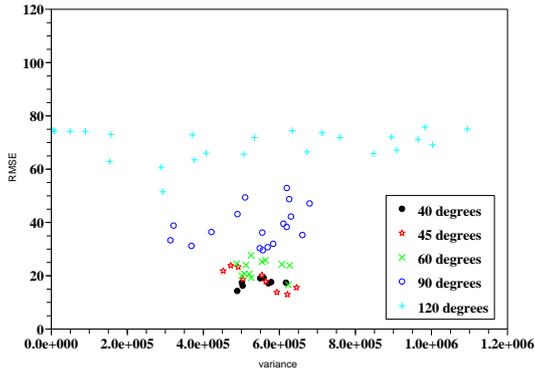


図 B.4.7: obj7

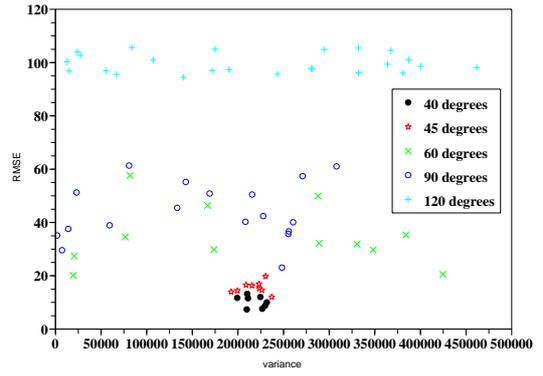


図 B.4.8: obj8

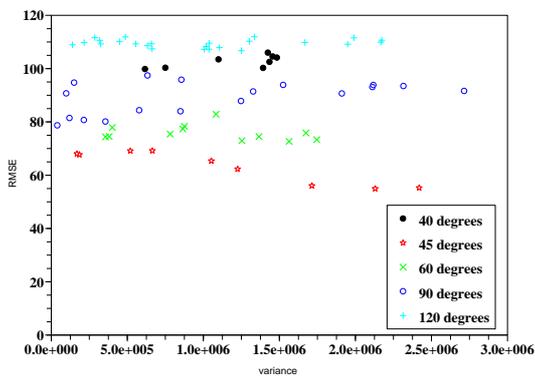


図 B.4.9: obj9

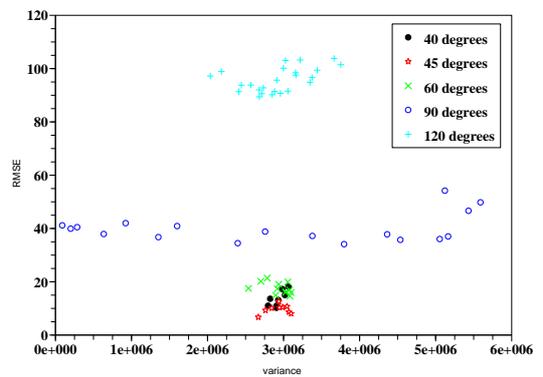


図 B.4.10: obj10

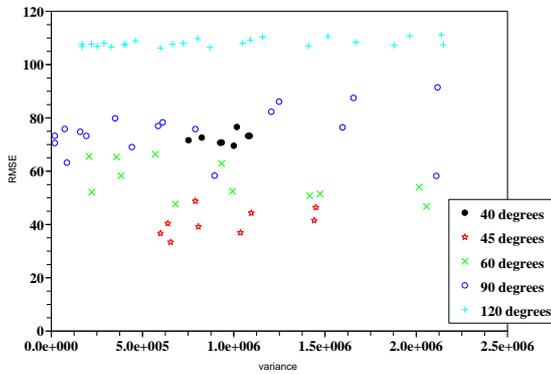


図 B.4.11: obj11

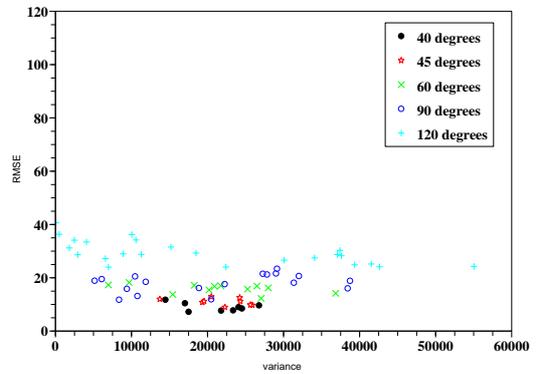


図 B.4.12: obj12

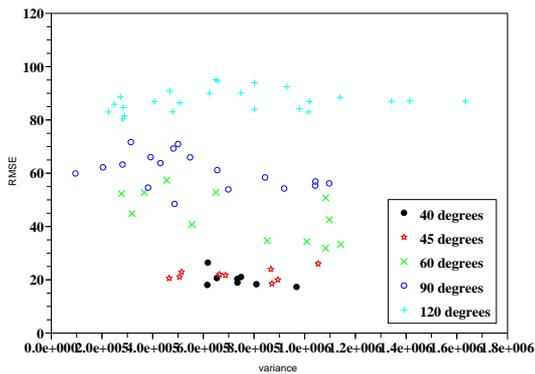


図 B.4.13: obj13

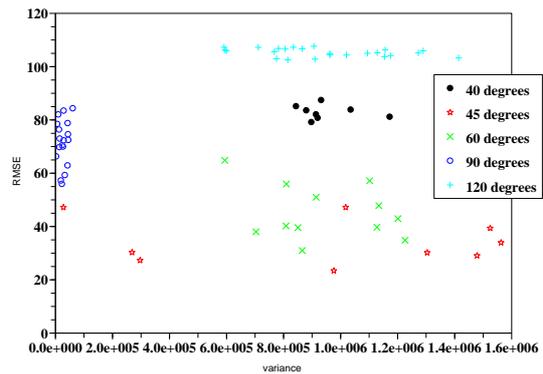


図 B.4.14: obj14

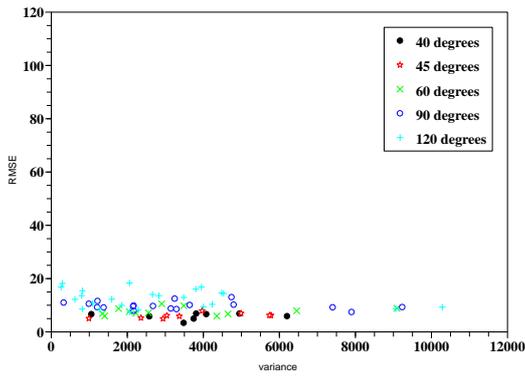


図 B.4.15: obj15

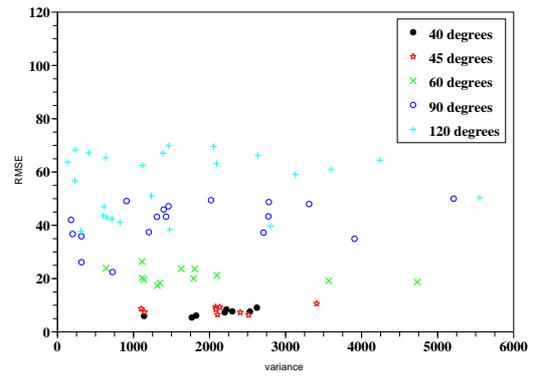


図 B.4.16: obj16

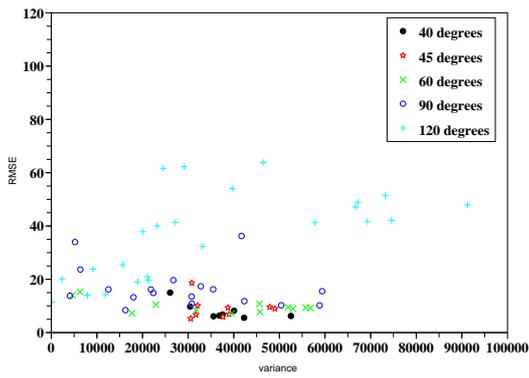


図 B.4.17: obj17

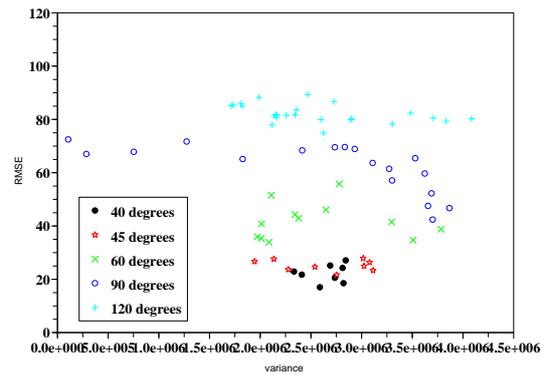


図 B.4.18: obj18

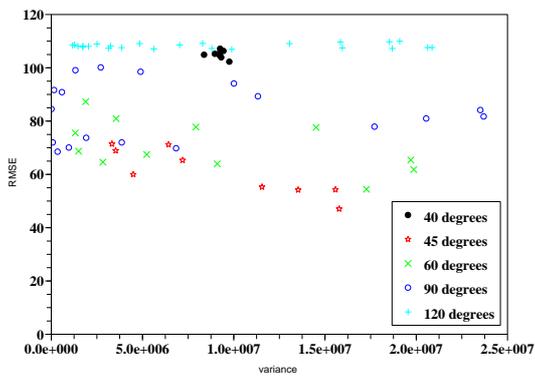


図 B.4.19: obj19

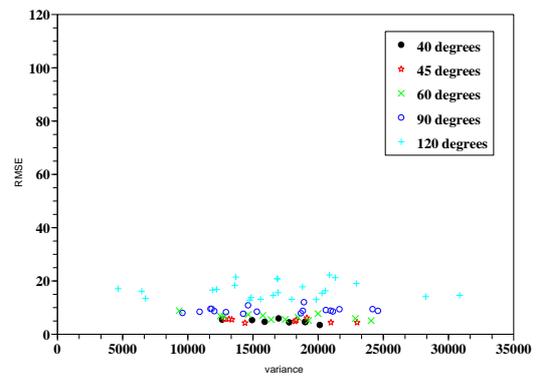


図 B.4.20: obj20

## B.5 画像の相関 (COIL-20)

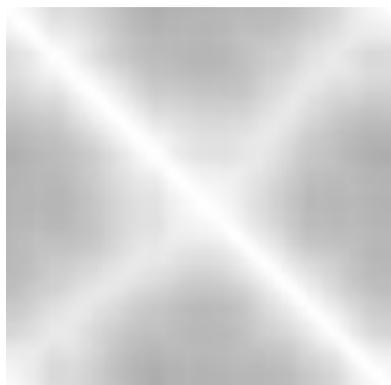


図 B.5.1: obj1

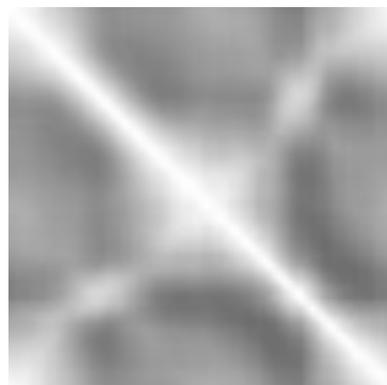


図 B.5.2: obj2

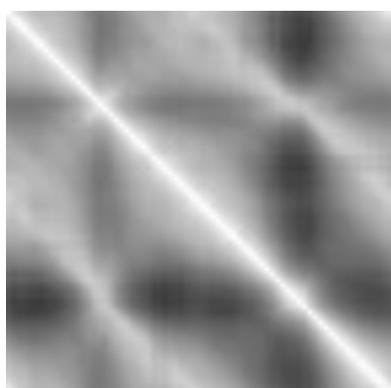


図 B.5.3: obj3



図 B.5.4: obj4

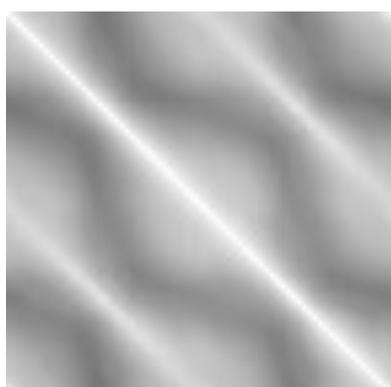


図 B.5.5: obj5

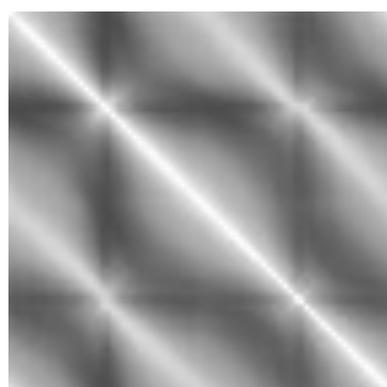


図 B.5.6: obj6

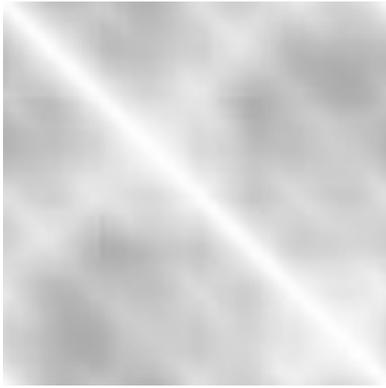


図 B.5.7: obj7



図 B.5.8: obj8

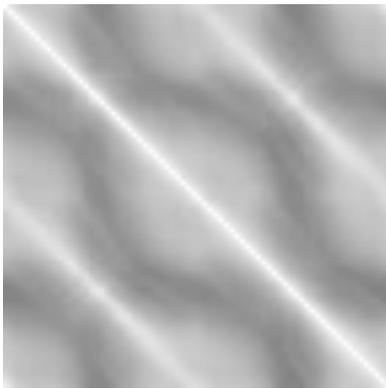


図 B.5.9: obj9

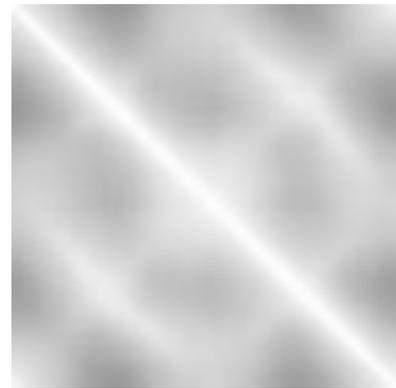


図 B.5.10: obj10



図 B.5.11: obj11



図 B.5.12: obj12



図 B.5.13: obj13



図 B.5.14: obj14



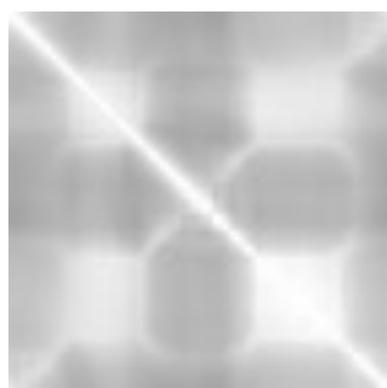
☒ B.5.15: obj15



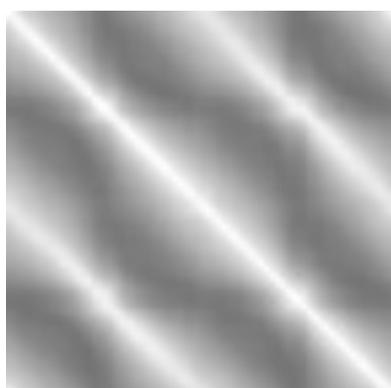
☒ B.5.16: obj16



☒ B.5.17: obj17



☒ B.5.18: obj18



☒ B.5.19: obj19



☒ B.5.20: obj20

## B.6 サンプル角を細かくして検討 (COIL-20)

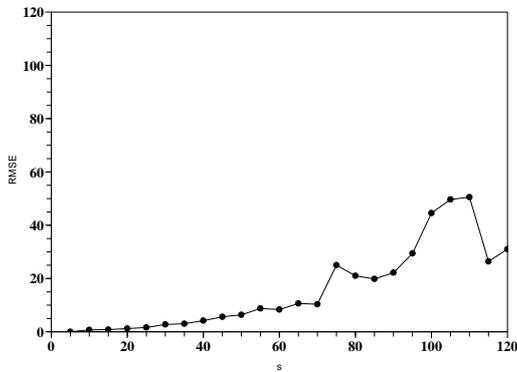


図 B.6.1: obj1

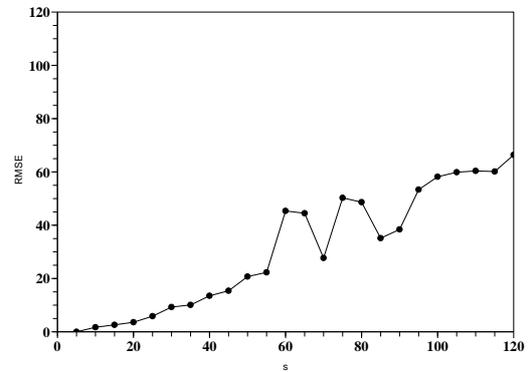


図 B.6.2: obj2

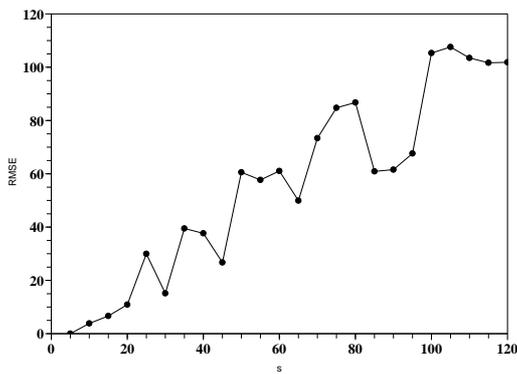


図 B.6.3: obj3

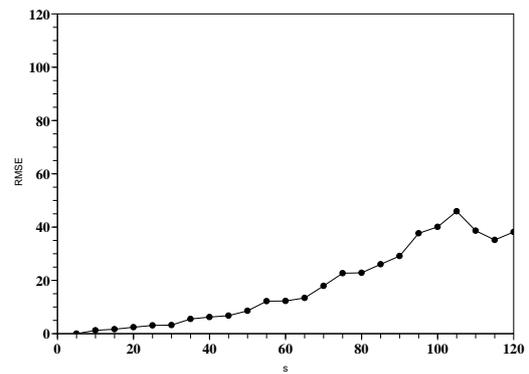


図 B.6.4: obj4

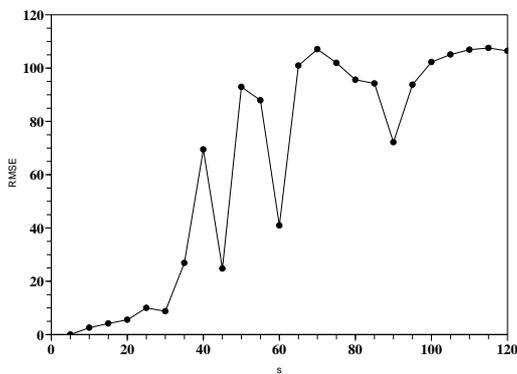


図 B.6.5: obj5

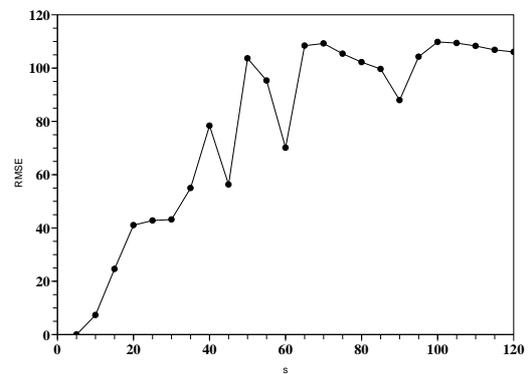


図 B.6.6: obj6

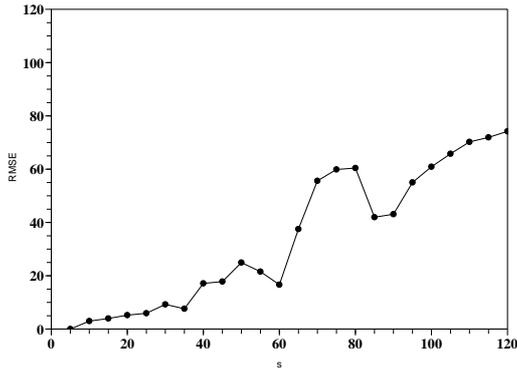


图 B.6.7: obj7

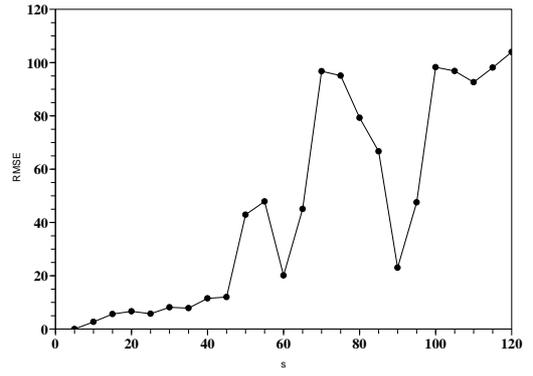


图 B.6.8: obj8

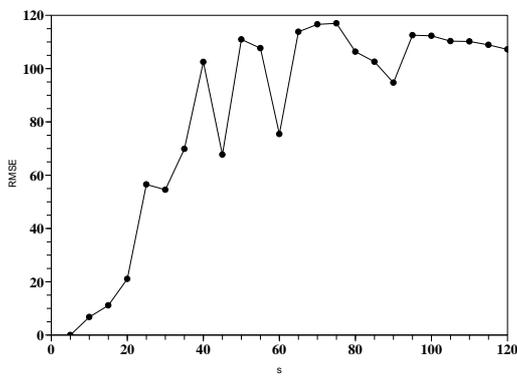


图 B.6.9: obj9

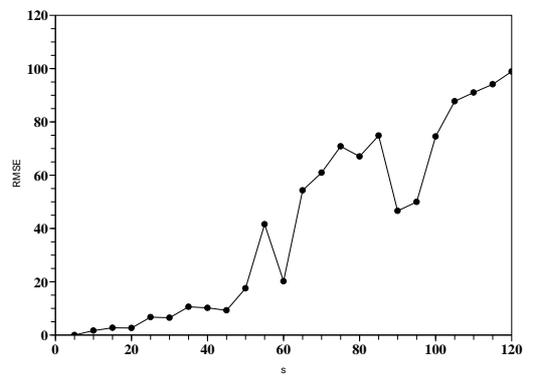


图 B.6.10: obj10

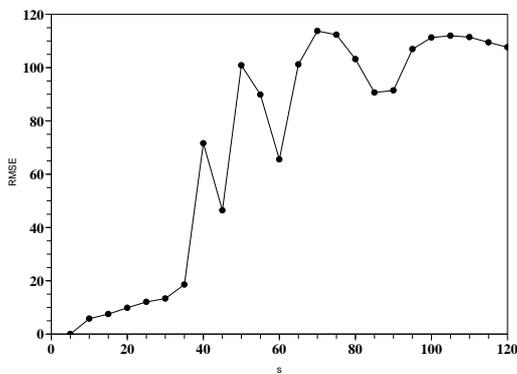


图 B.6.11: obj11

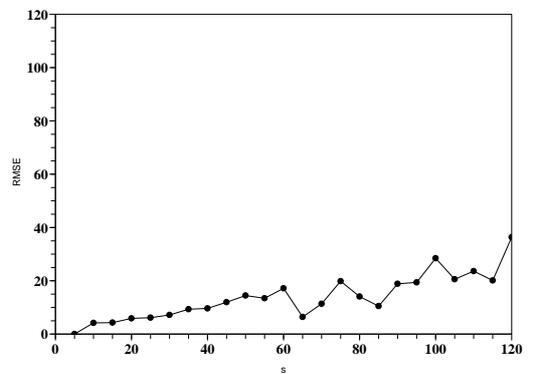


图 B.6.12: obj12

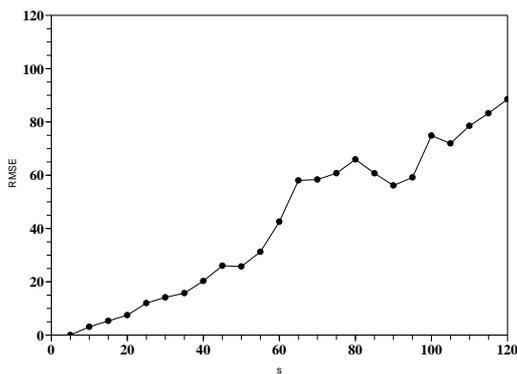


图 B.6.13: obj13

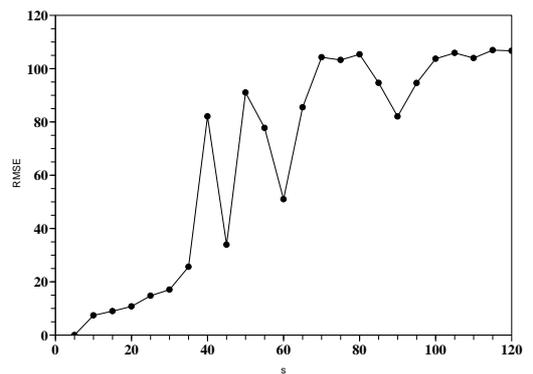


图 B.6.14: obj14

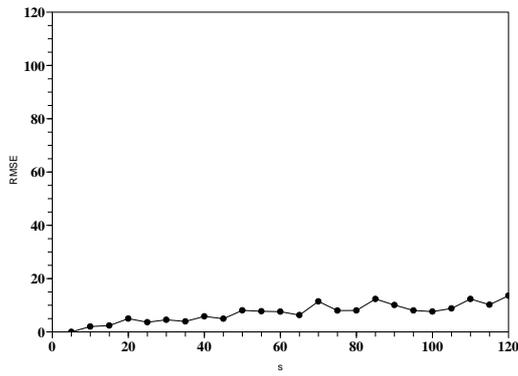


図 B.6.15: obj15

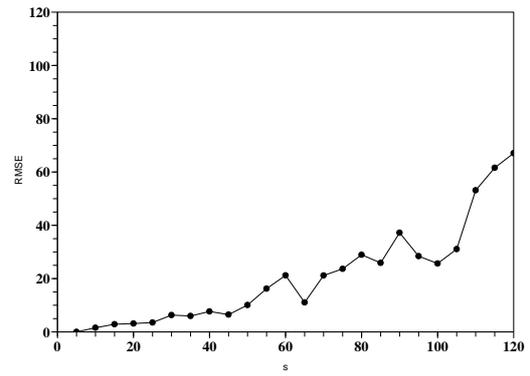


図 B.6.16: obj16

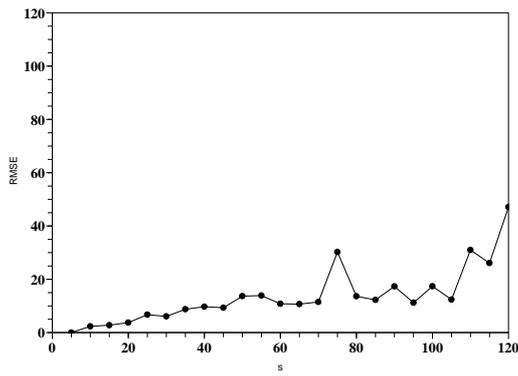


図 B.6.17: obj17

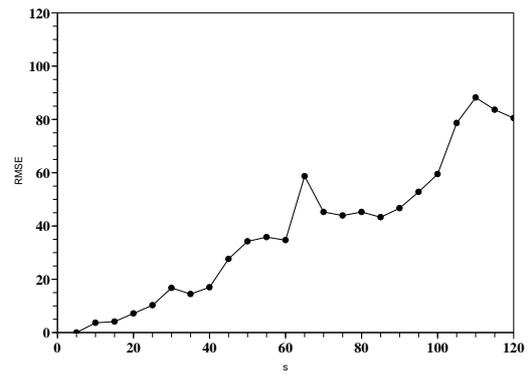


図 B.6.18: obj18

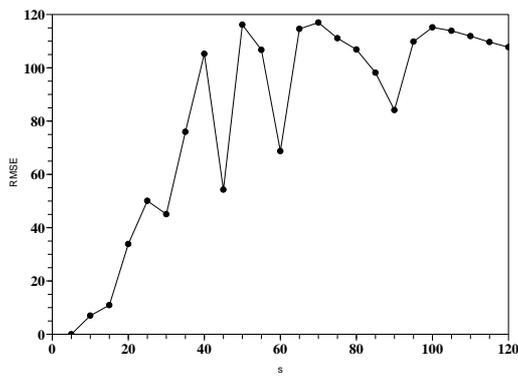


図 B.6.19: obj19

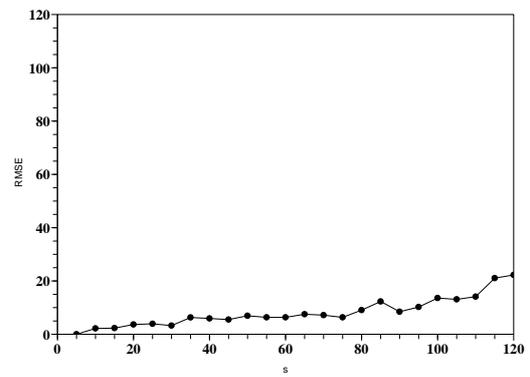
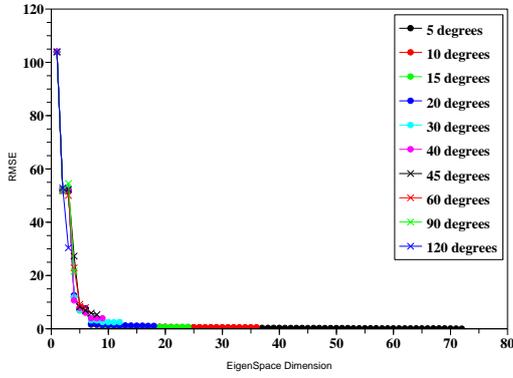
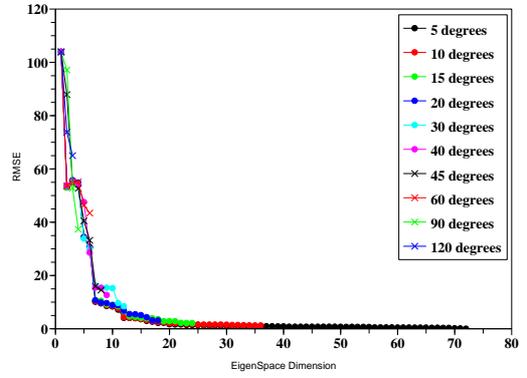


図 B.6.20: obj20

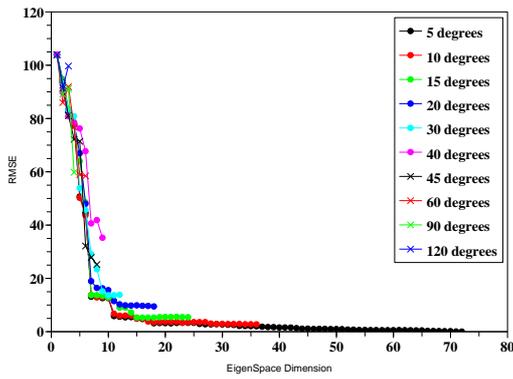
## B.7 固有空間削減 (COIL-20)



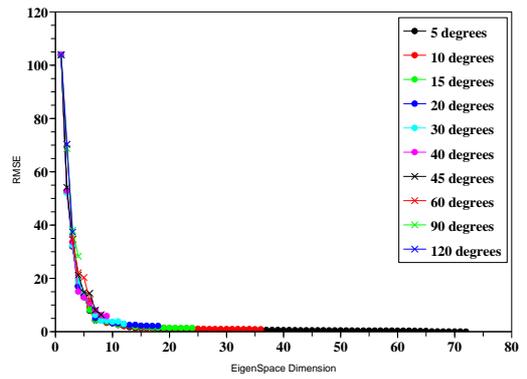
☒ B.7.1: obj1



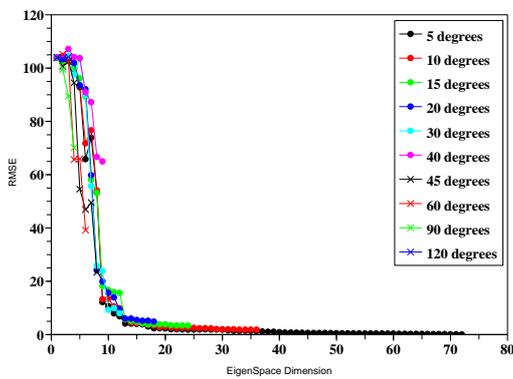
☒ B.7.2: obj2



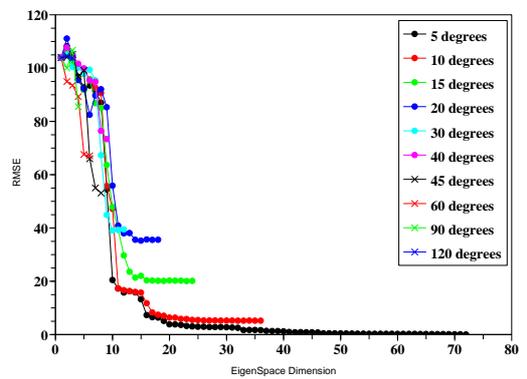
☒ B.7.3: obj3



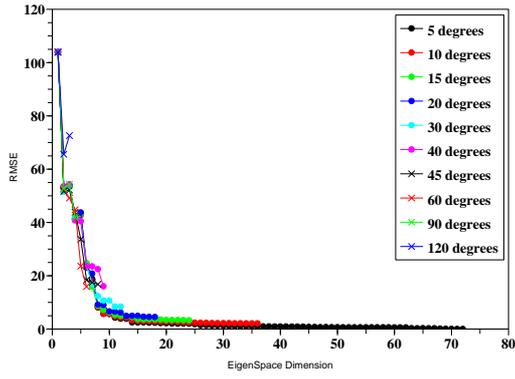
☒ B.7.4: obj4



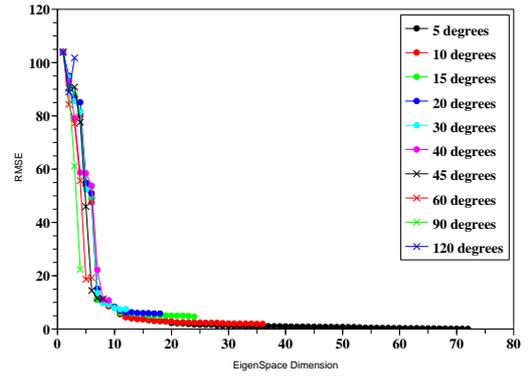
☒ B.7.5: obj5



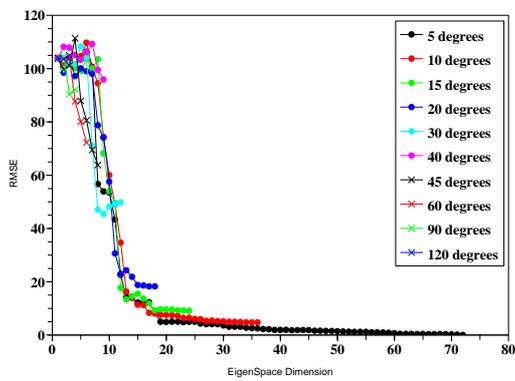
☒ B.7.6: obj6



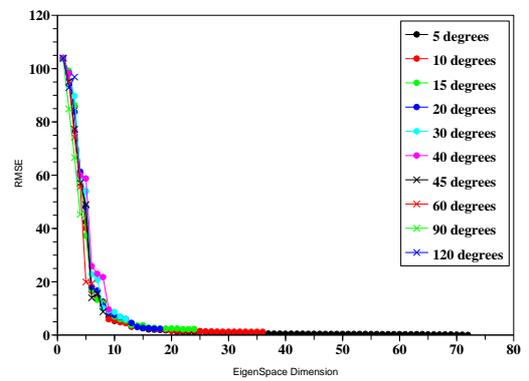
B.7.7: obj7



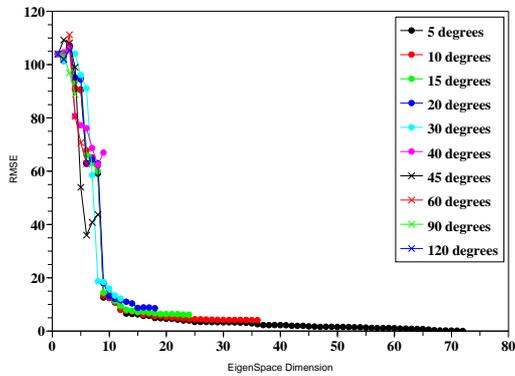
B.7.8: obj8



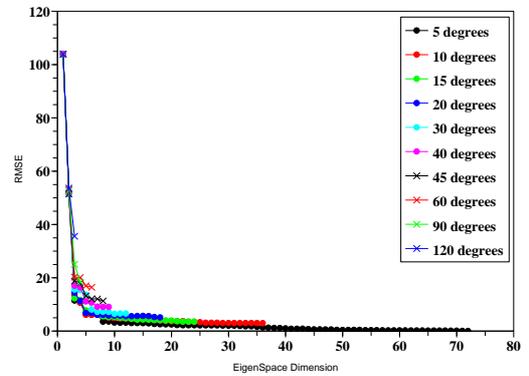
B.7.9: obj9



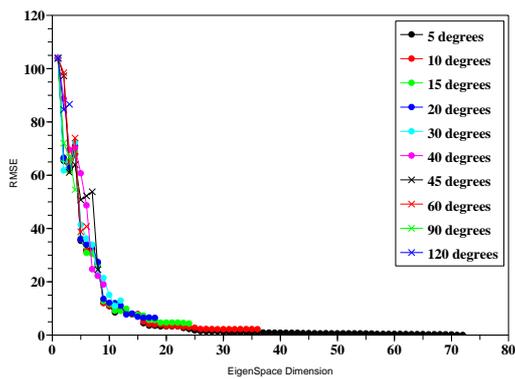
B.7.10: obj10



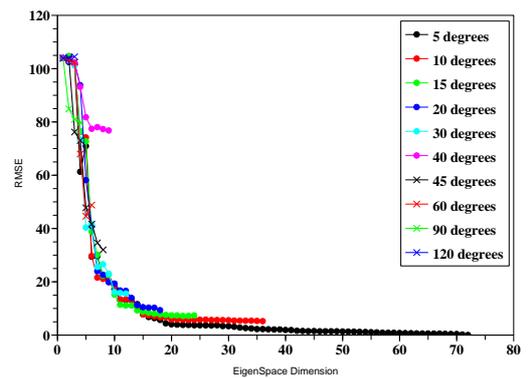
B.7.11: obj11



B.7.12: obj12



B.7.13: obj13



B.7.14: obj14

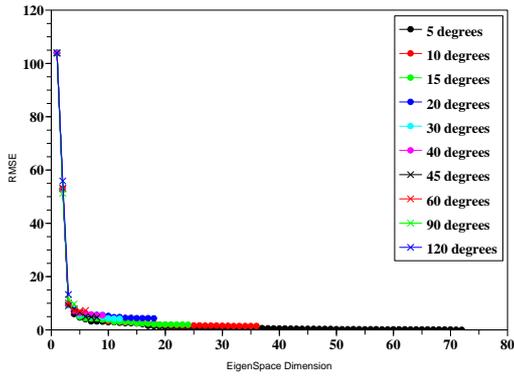


図 B.7.15: obj15

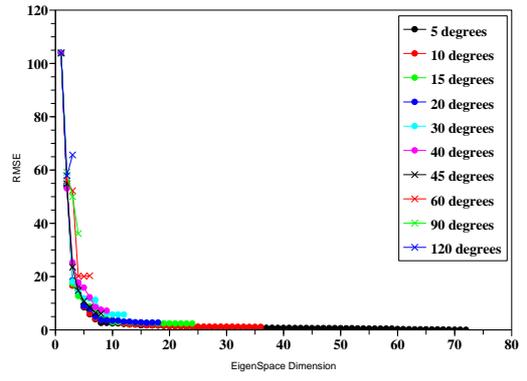


図 B.7.16: obj16

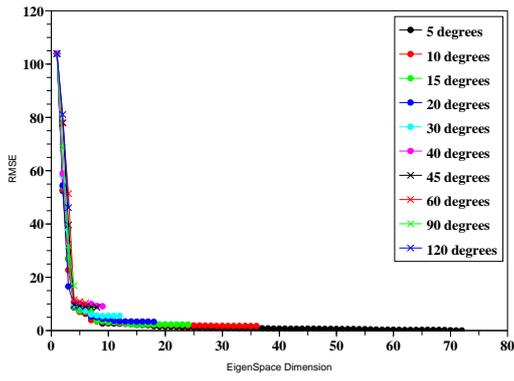


図 B.7.17: obj17

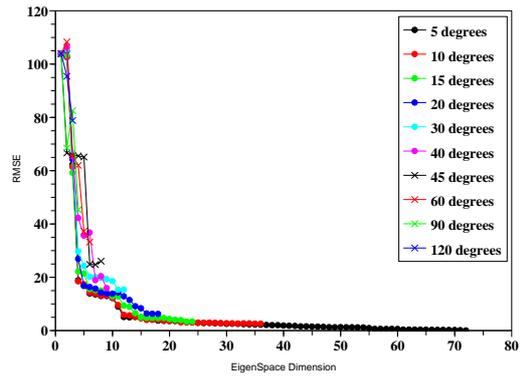


図 B.7.18: obj18

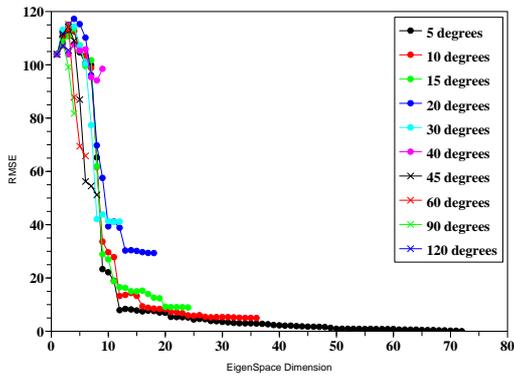


図 B.7.19: obj19

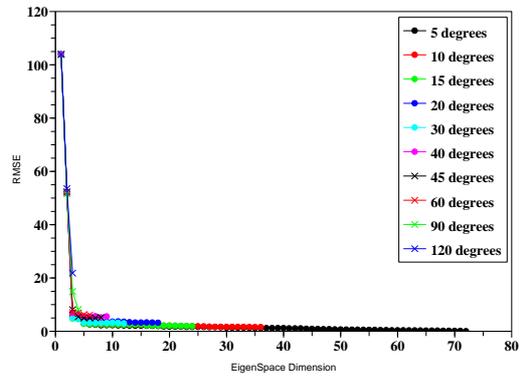


図 B.7.20: obj20

## B.8 固有空間削減 (COIL-100)

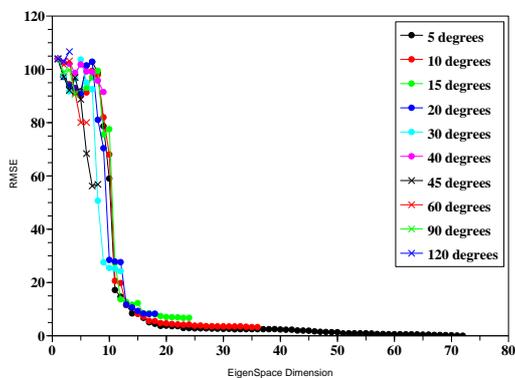


図 B.8.1: obj1

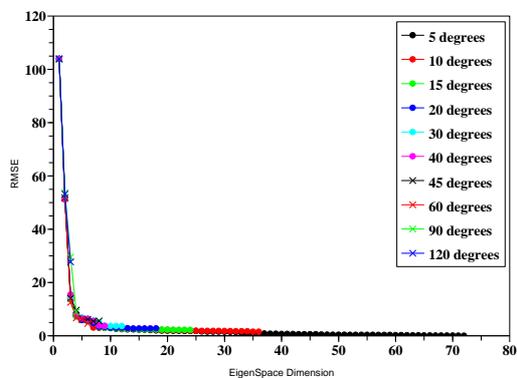


図 B.8.2: obj2

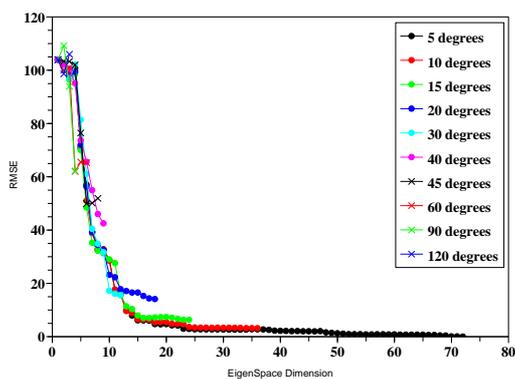


図 B.8.3: obj3

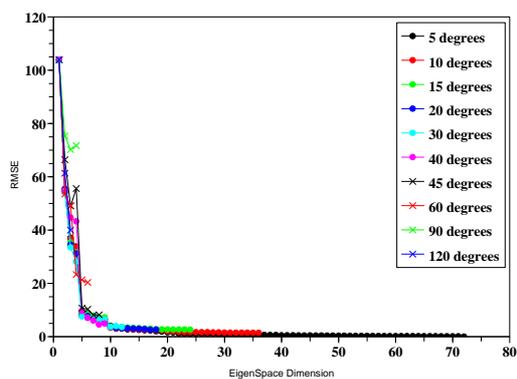


図 B.8.4: obj4

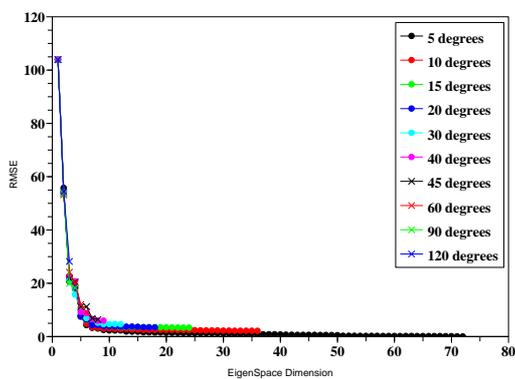


図 B.8.5: obj5

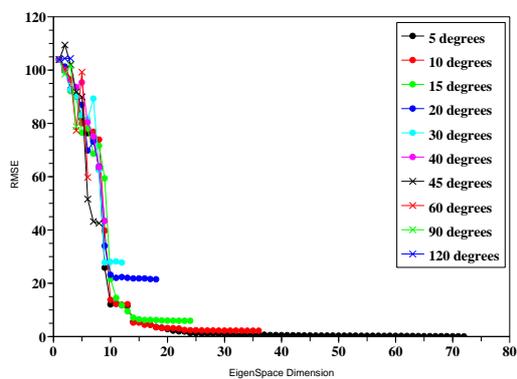
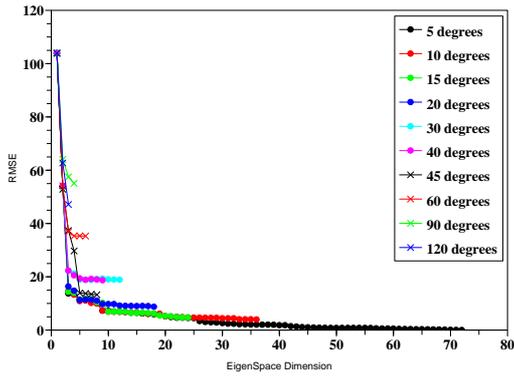
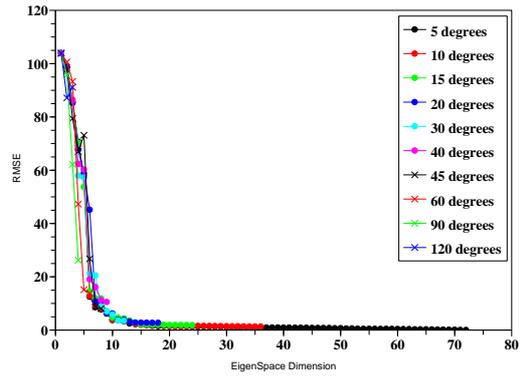


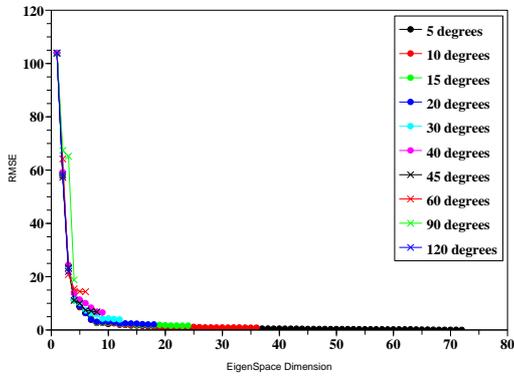
図 B.8.6: obj6



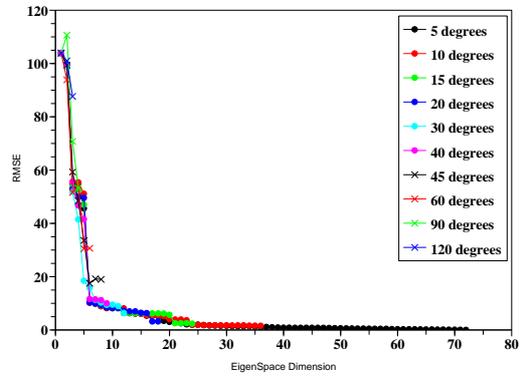
☒ B.8.7: obj7



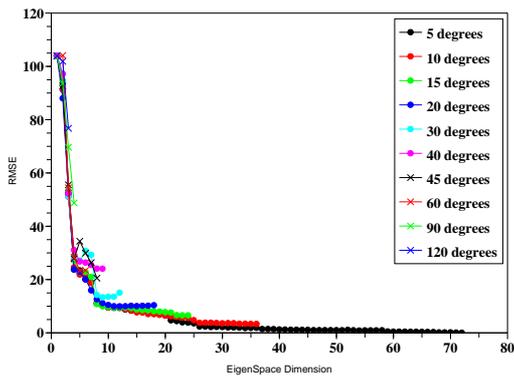
☒ B.8.8: obj8



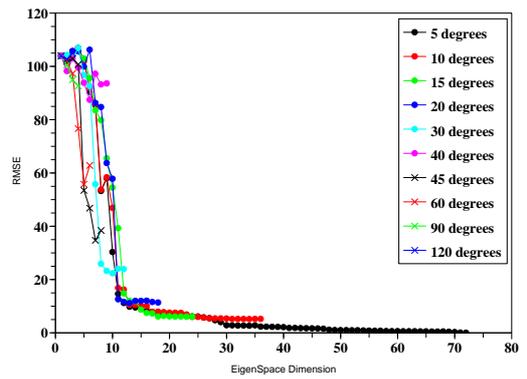
☒ B.8.9: obj9



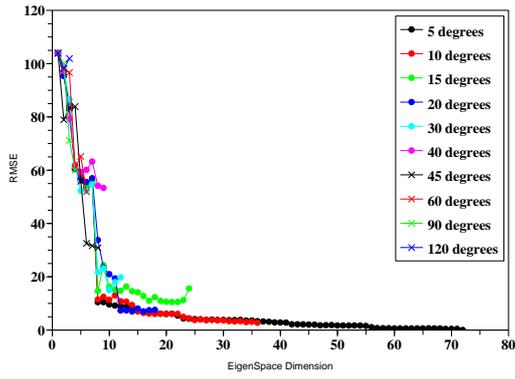
☒ B.8.10: obj10



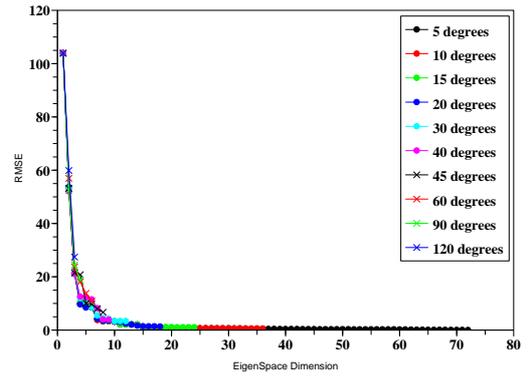
☒ B.8.11: obj11



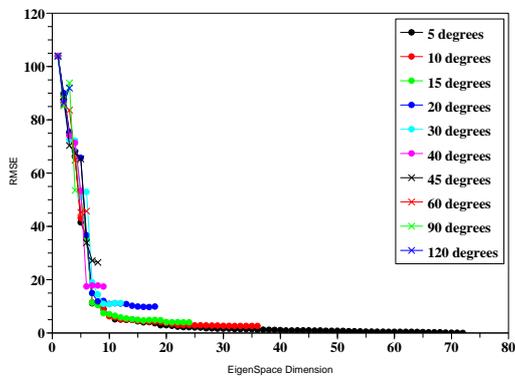
☒ B.8.12: obj12



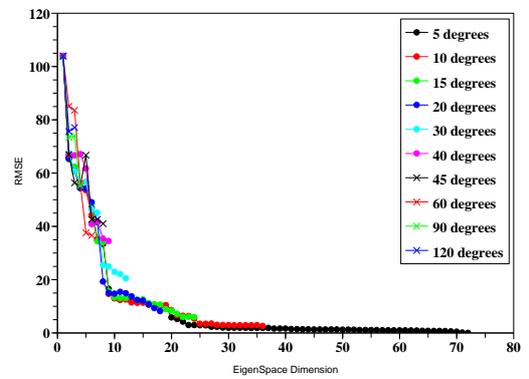
☒ B.8.13: obj13



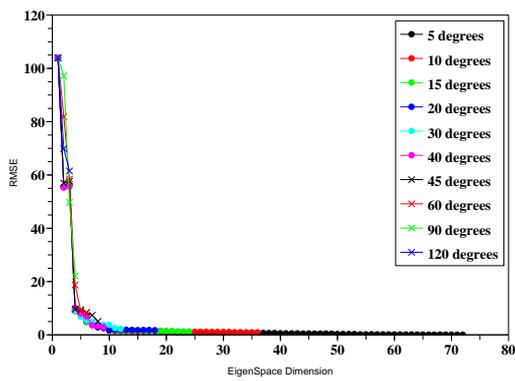
☒ B.8.14: obj14



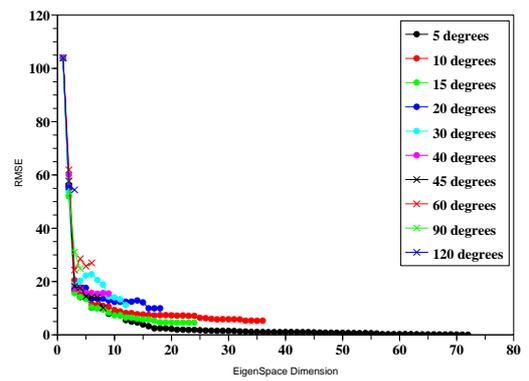
☒ B.8.15: obj15



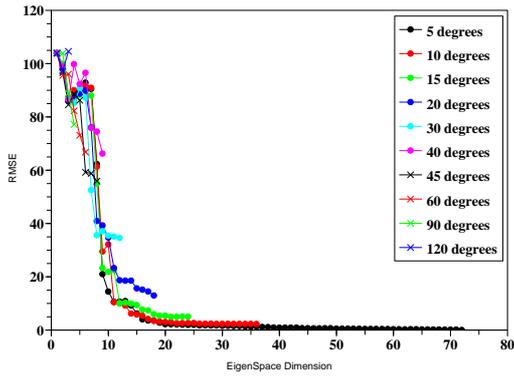
☒ B.8.16: obj16



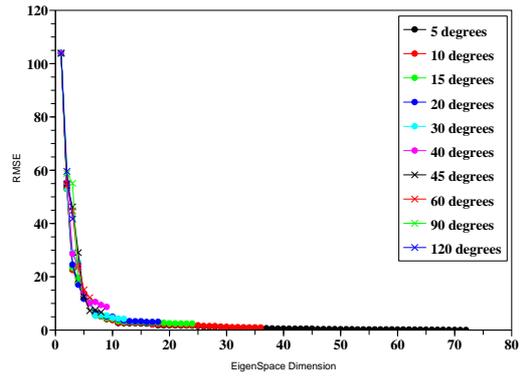
☒ B.8.17: obj17



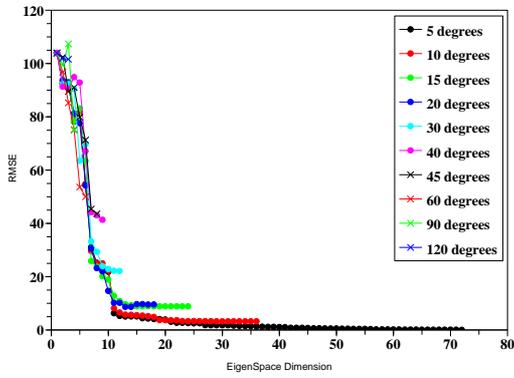
☒ B.8.18: obj18



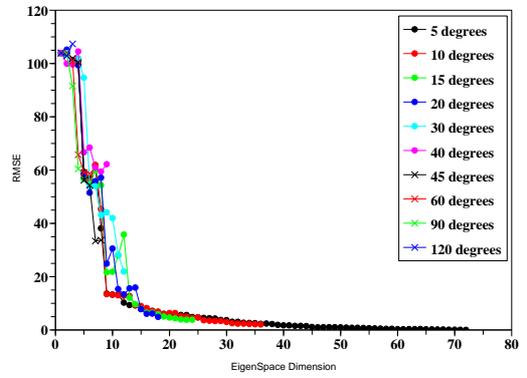
☒ B.8.19: obj19



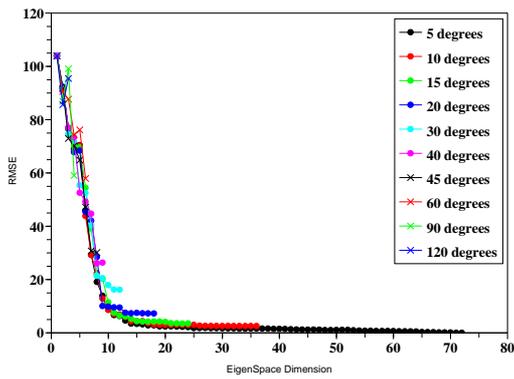
☒ B.8.20: obj20



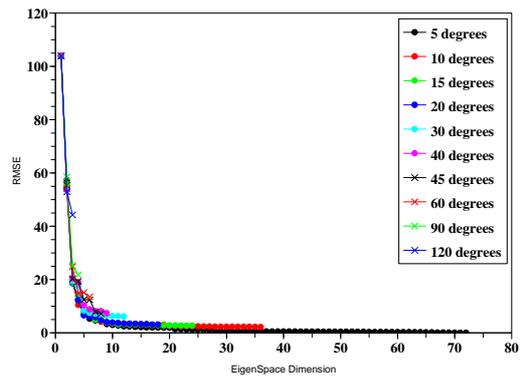
☒ B.8.21: obj21



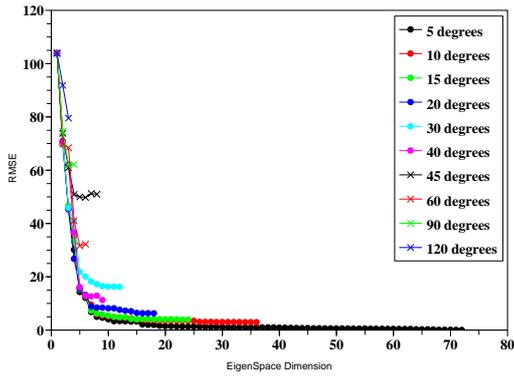
☒ B.8.22: obj22



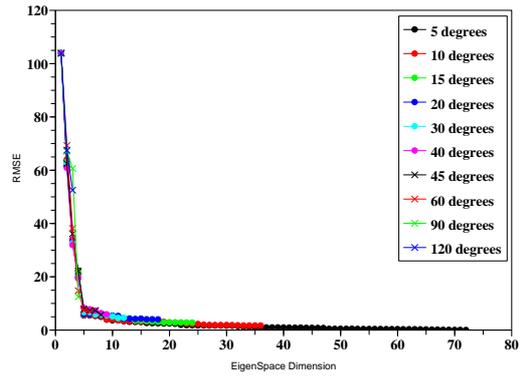
☒ B.8.23: obj23



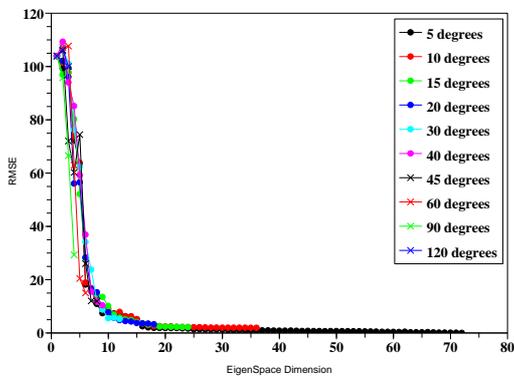
☒ B.8.24: obj24



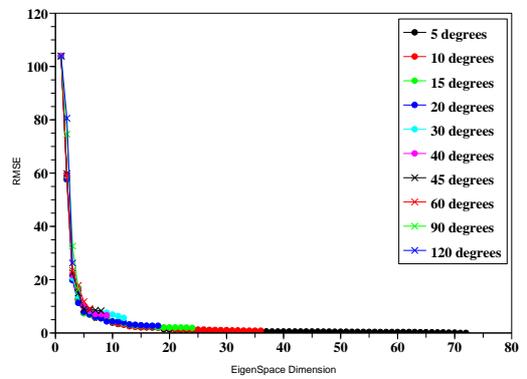
☒ B.8.25: obj25



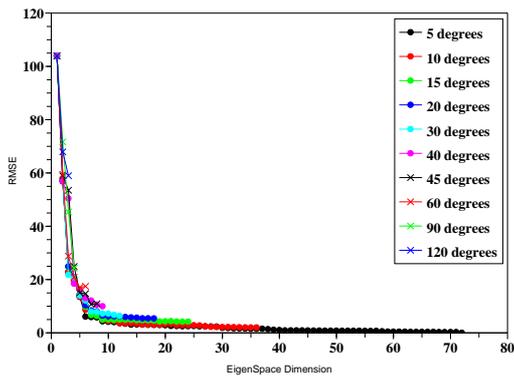
☒ B.8.26: obj26



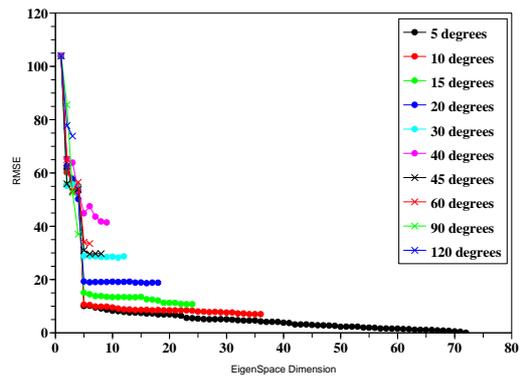
☒ B.8.27: obj27



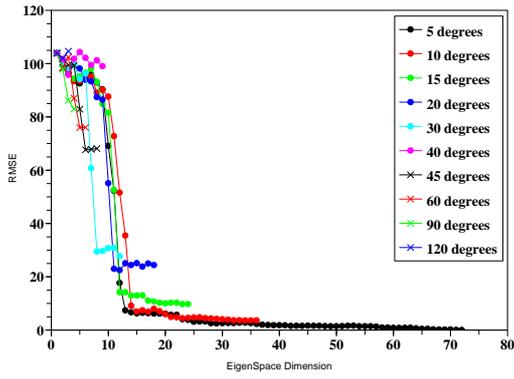
☒ B.8.28: obj28



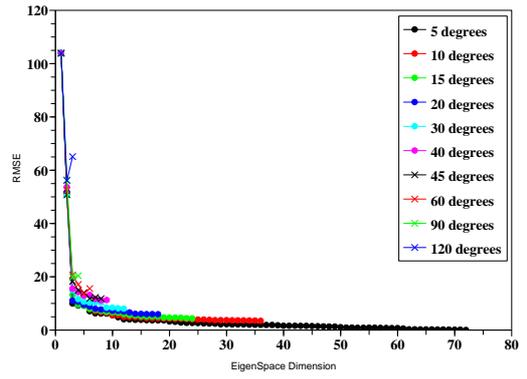
☒ B.8.29: obj29



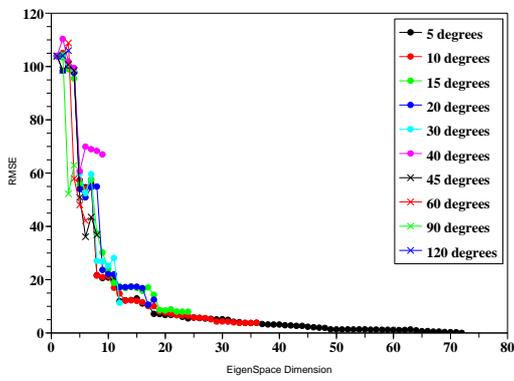
☒ B.8.30: obj30



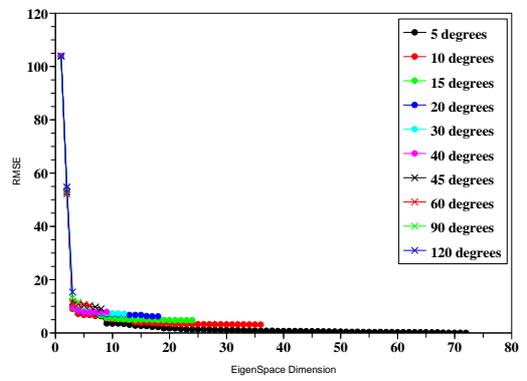
☒ B.8.31: obj31



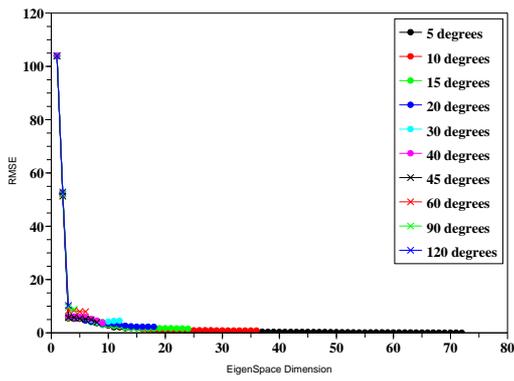
☒ B.8.32: obj32



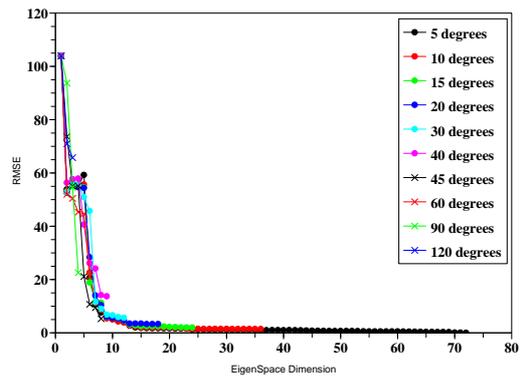
☒ B.8.33: obj33



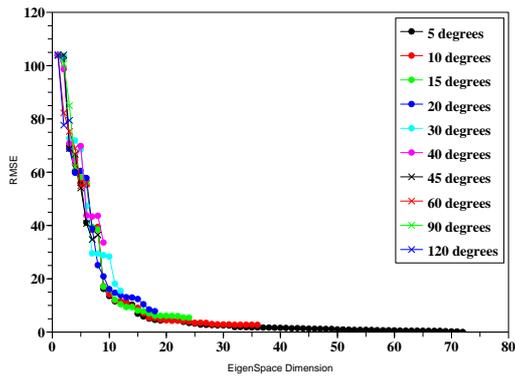
☒ B.8.34: obj34



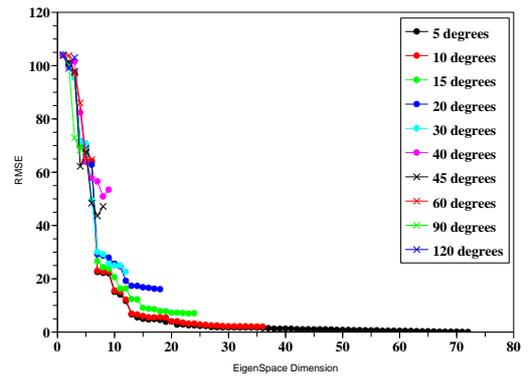
☒ B.8.35: obj35



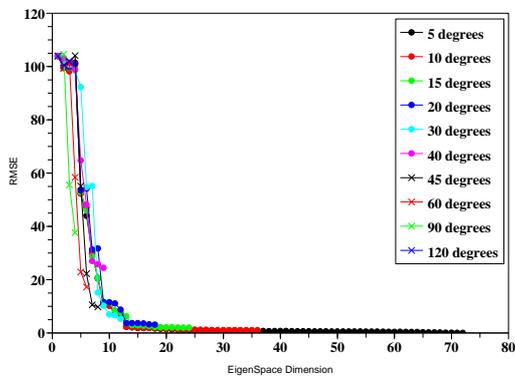
☒ B.8.36: obj36



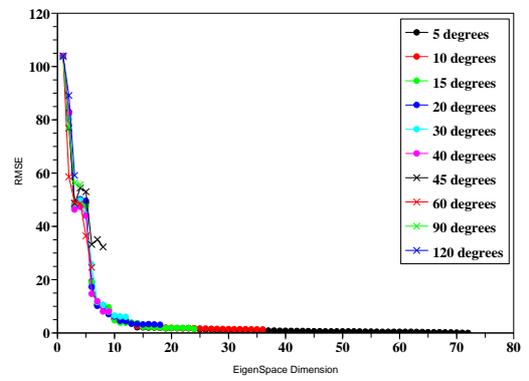
☒ B.8.37: obj37



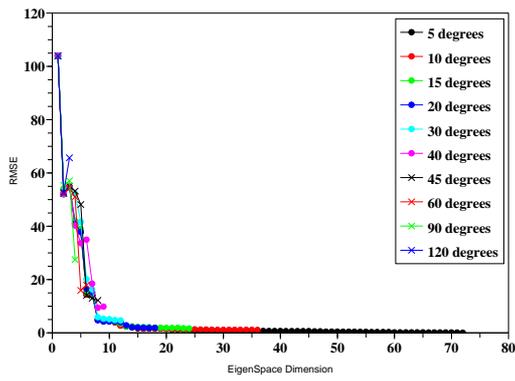
☒ B.8.38: obj38



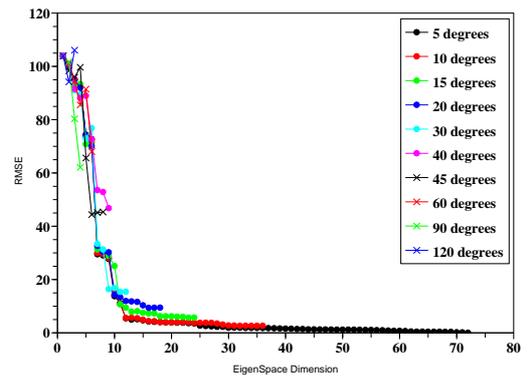
☒ B.8.39: obj39



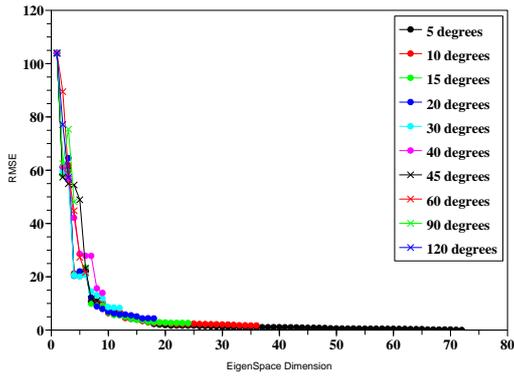
☒ B.8.40: obj40



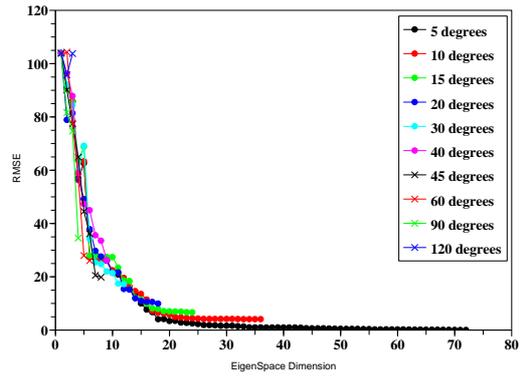
☒ B.8.41: obj41



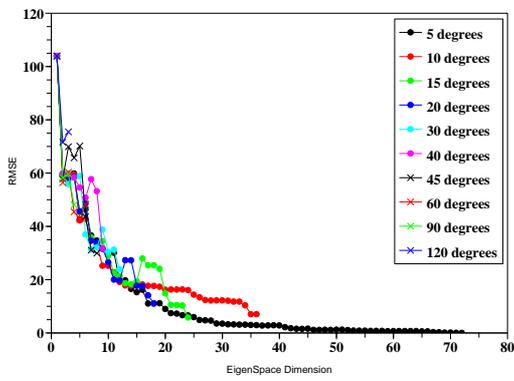
☒ B.8.42: obj42



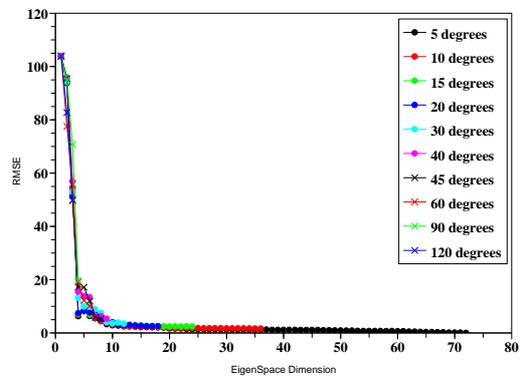
☒ B.8.43: obj43



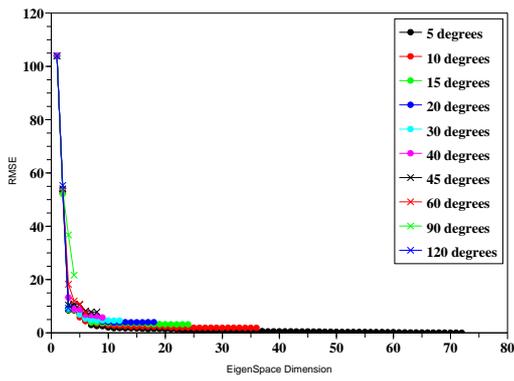
☒ B.8.44: obj44



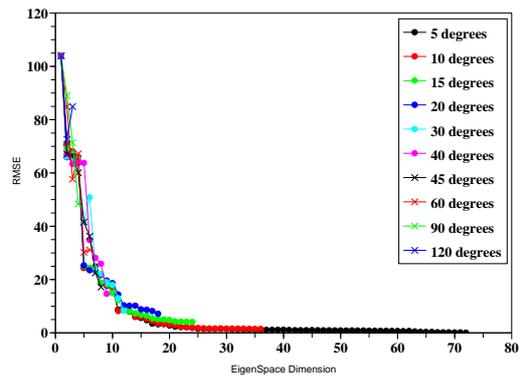
☒ B.8.45: obj45



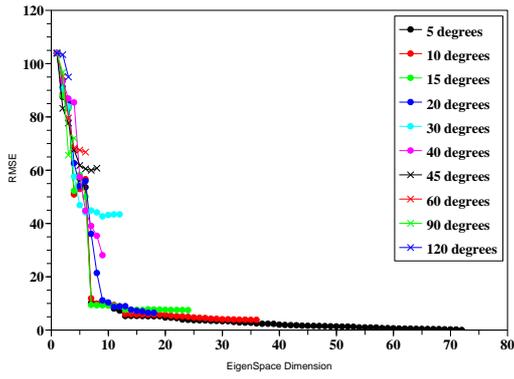
☒ B.8.46: obj46



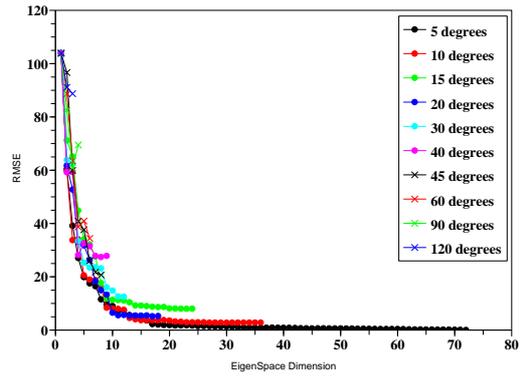
☒ B.8.47: obj47



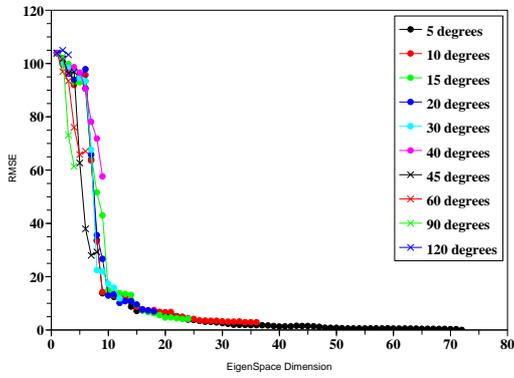
☒ B.8.48: obj48



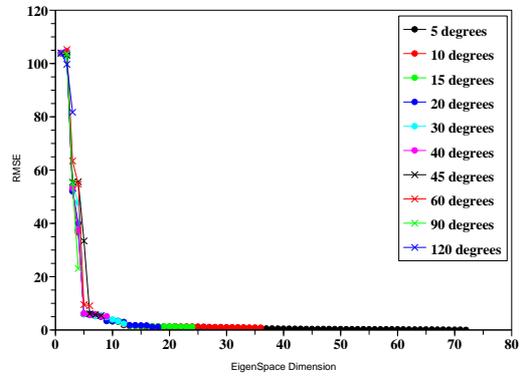
☒ B.8.49: obj49



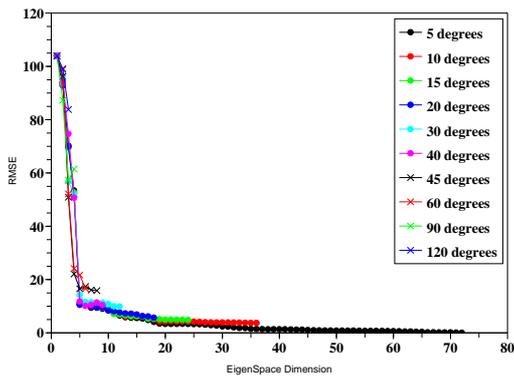
☒ B.8.50: obj50



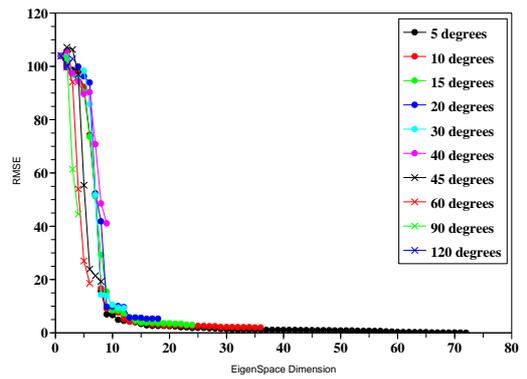
☒ B.8.51: obj51



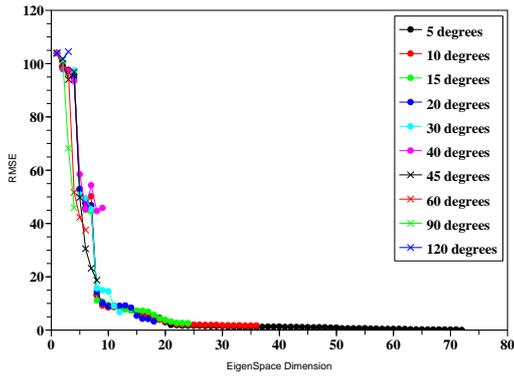
☒ B.8.52: obj52



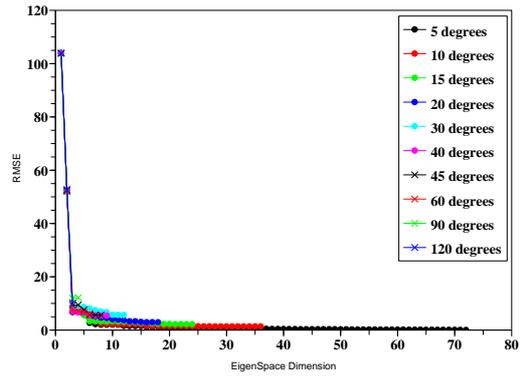
☒ B.8.53: obj53



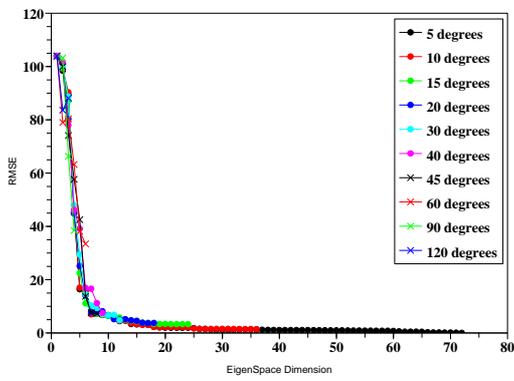
☒ B.8.54: obj54



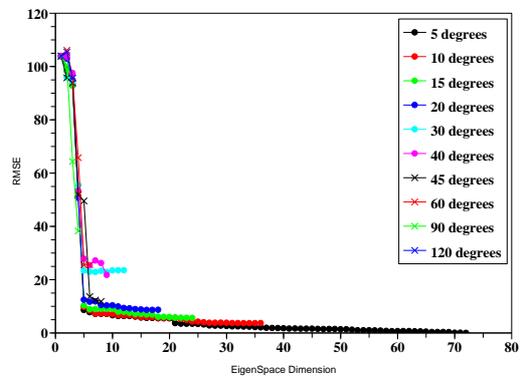
☒ B.8.55: obj55



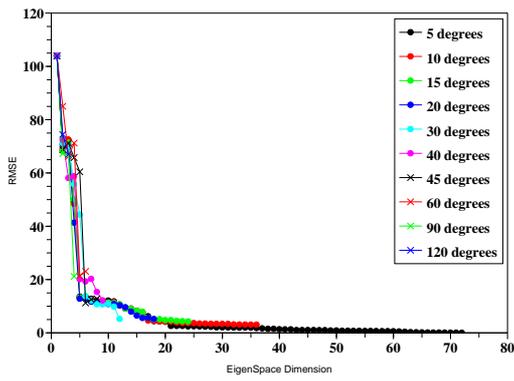
☒ B.8.56: obj56



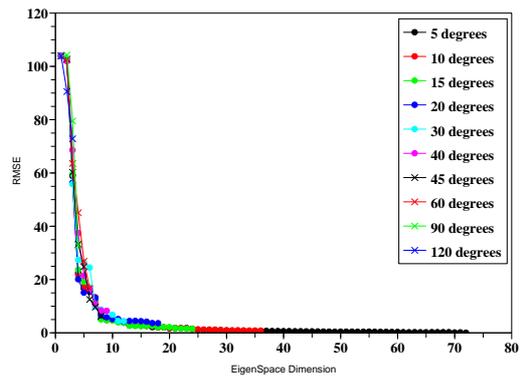
☒ B.8.57: obj57



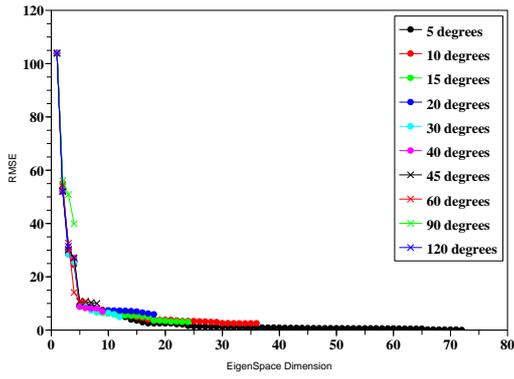
☒ B.8.58: obj58



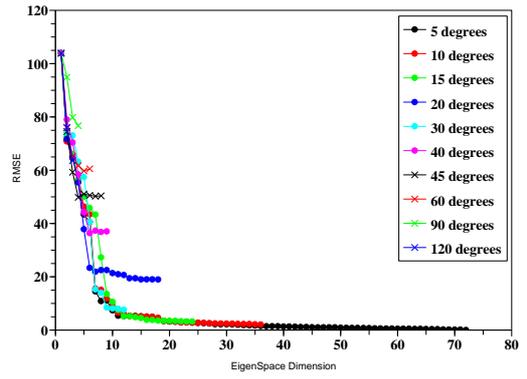
☒ B.8.59: obj59



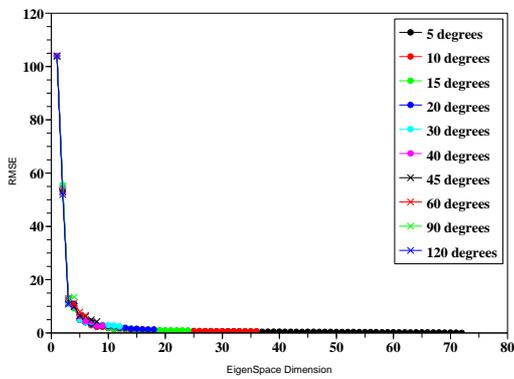
☒ B.8.60: obj60



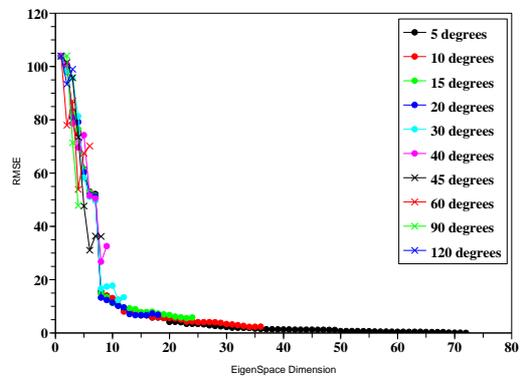
☒ B.8.61: obj61



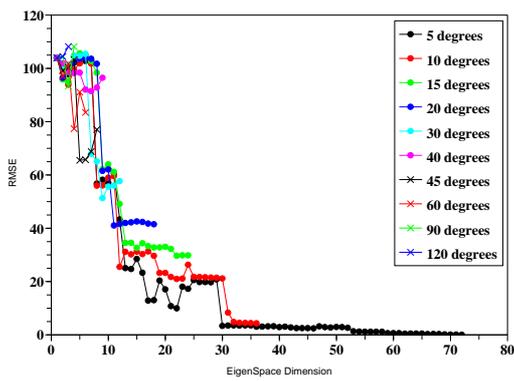
☒ B.8.62: obj62



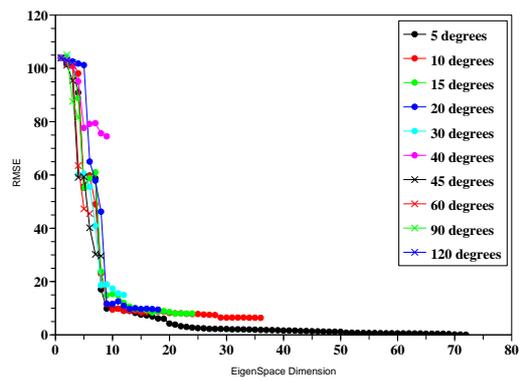
☒ B.8.63: obj63



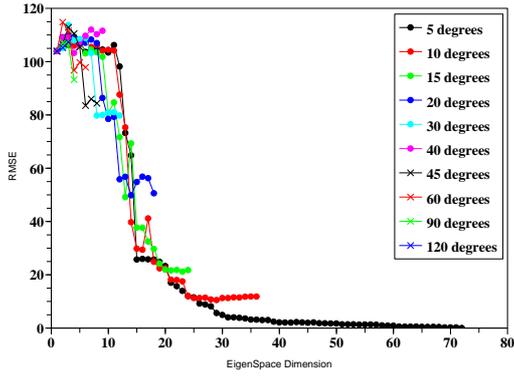
☒ B.8.64: obj64



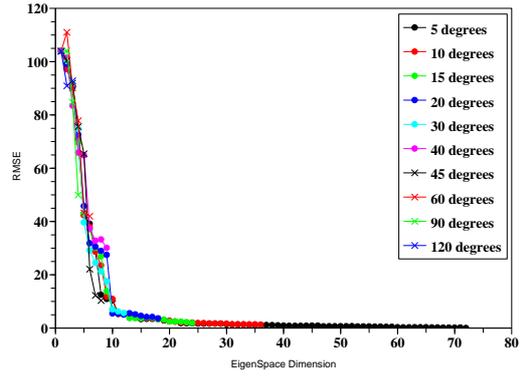
☒ B.8.65: obj65



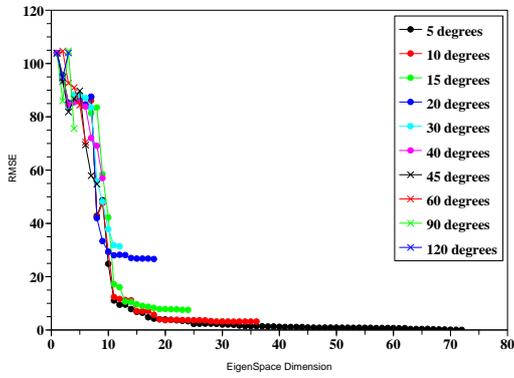
☒ B.8.66: obj66



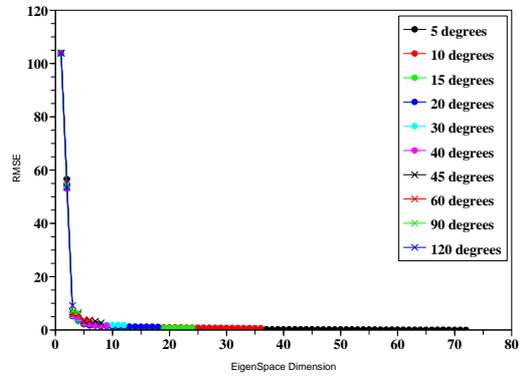
☒ B.8.67: obj67



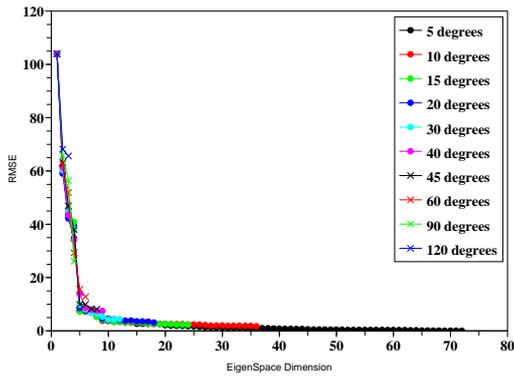
☒ B.8.68: obj68



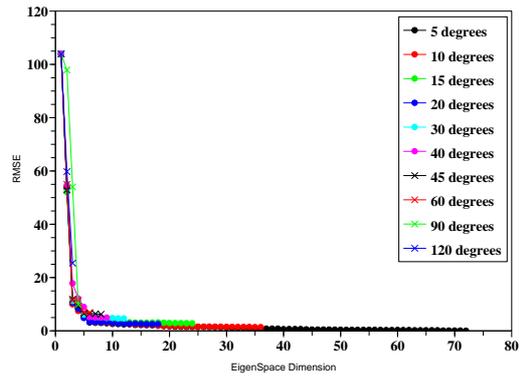
☒ B.8.69: obj69



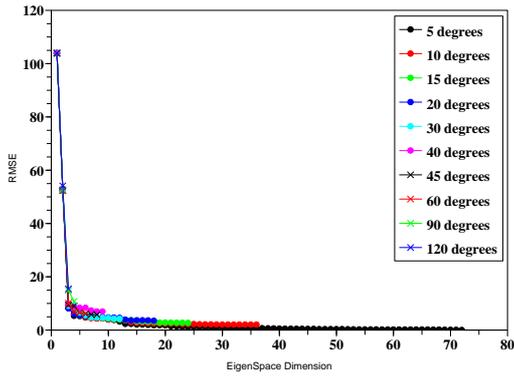
☒ B.8.70: obj70



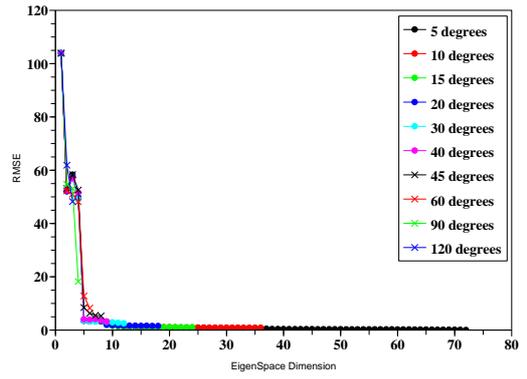
☒ B.8.71: obj71



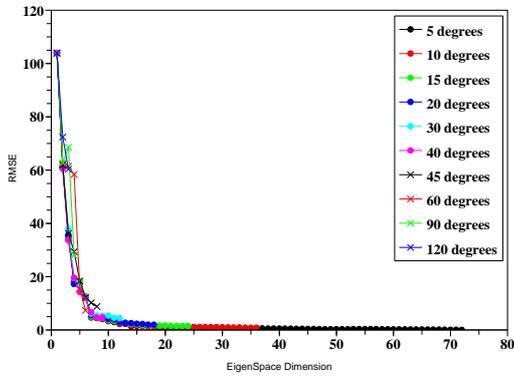
☒ B.8.72: obj72



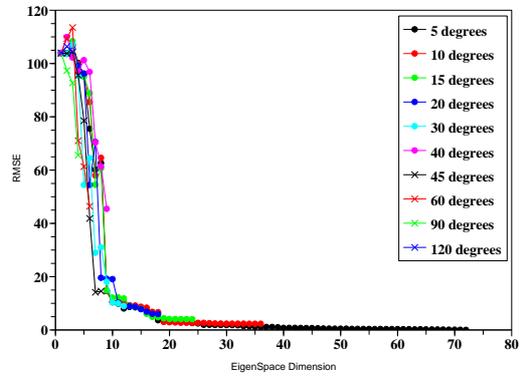
☒ B.8.73: obj73



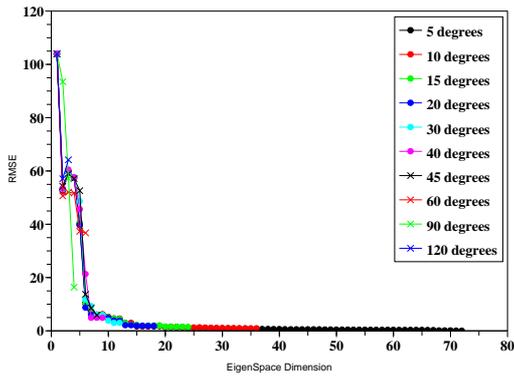
☒ B.8.74: obj74



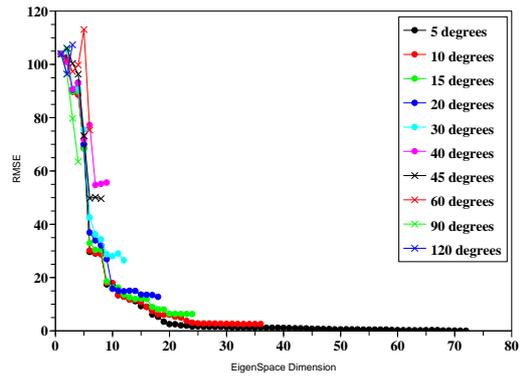
☒ B.8.75: obj75



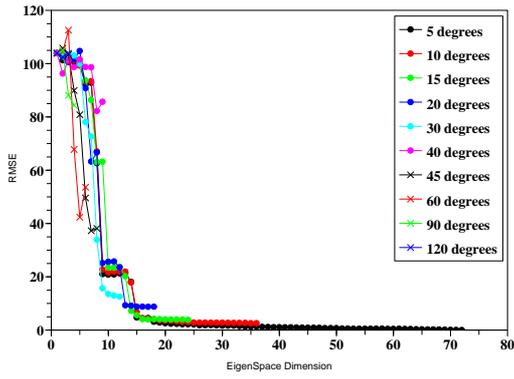
☒ B.8.76: obj76



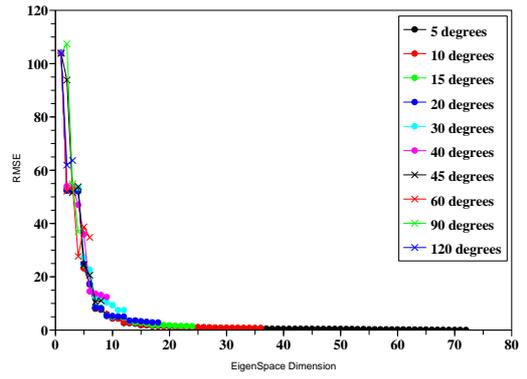
☒ B.8.77: obj77



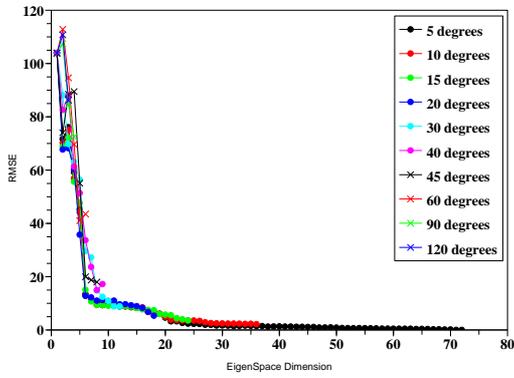
☒ B.8.78: obj78



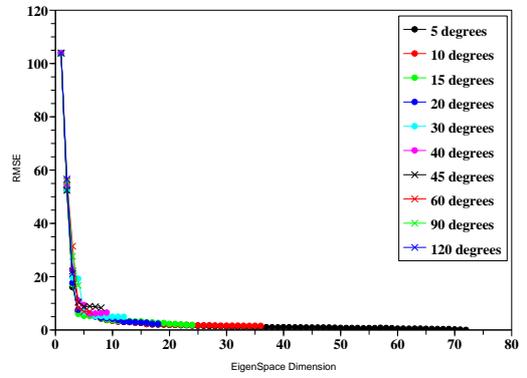
☒ B.8.79: obj79



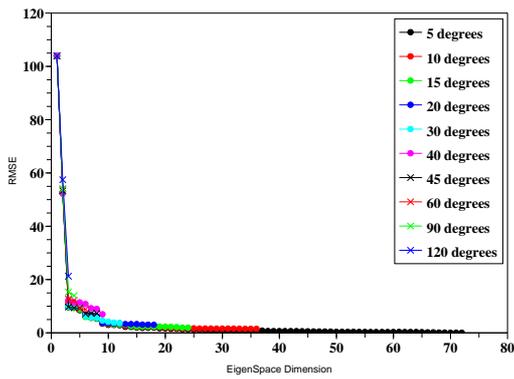
☒ B.8.80: obj80



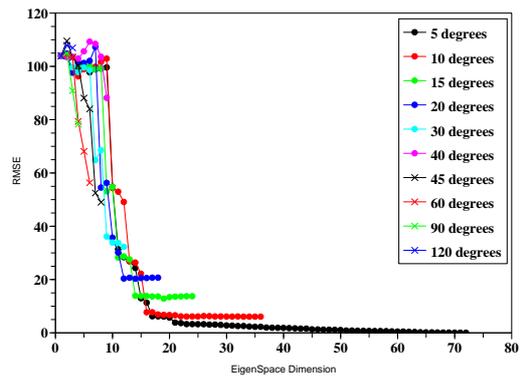
☒ B.8.81: obj81



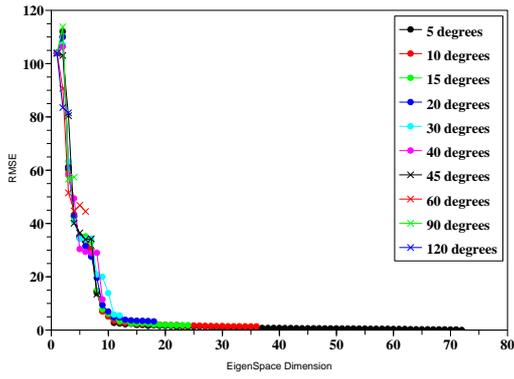
☒ B.8.82: obj82



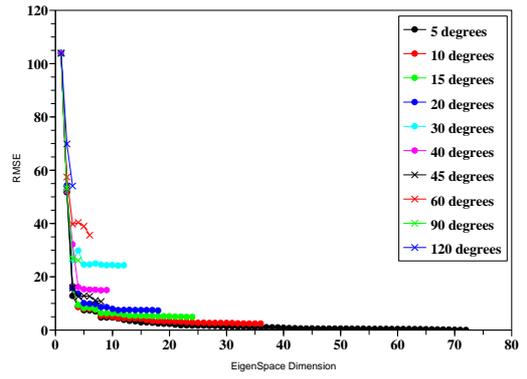
☒ B.8.83: obj83



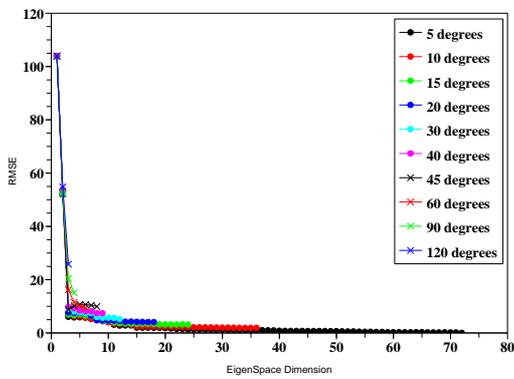
☒ B.8.84: obj84



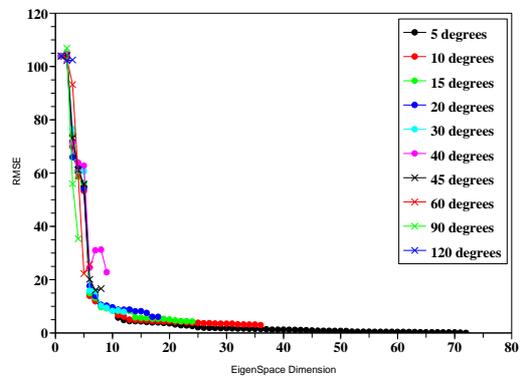
☒ B.8.85: obj85



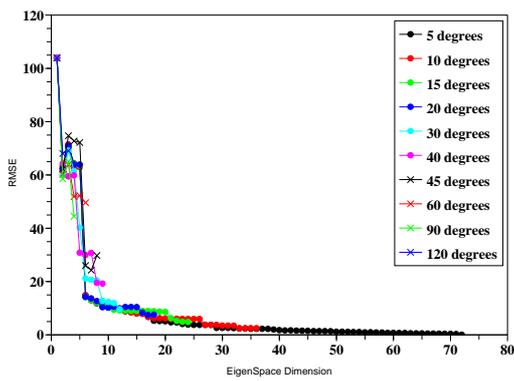
☒ B.8.86: obj86



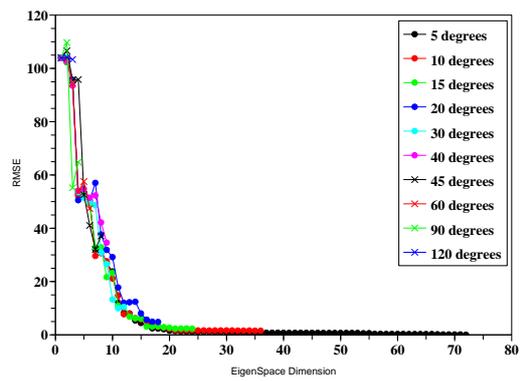
☒ B.8.87: obj87



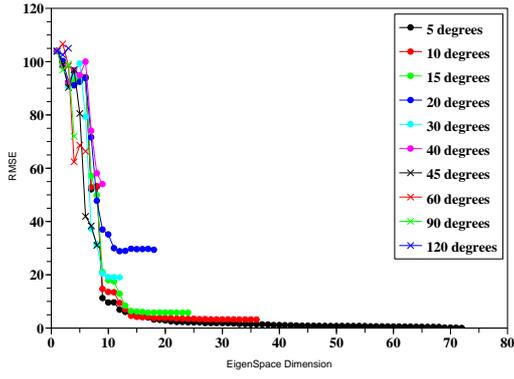
☒ B.8.88: obj88



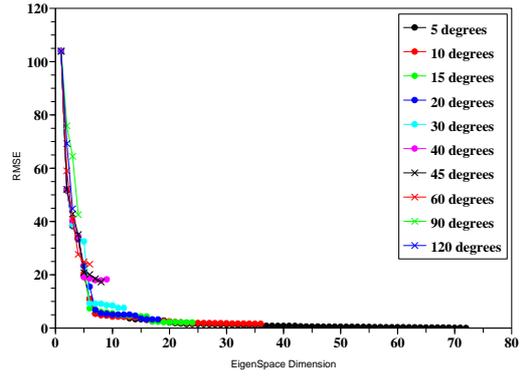
☒ B.8.89: obj89



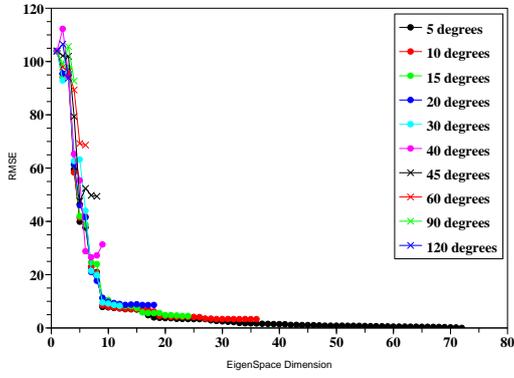
☒ B.8.90: obj90



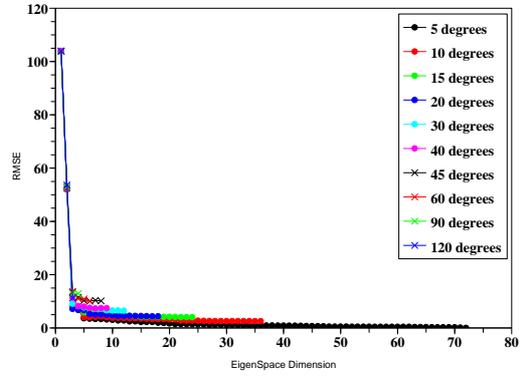
☒ B.8.91: obj91



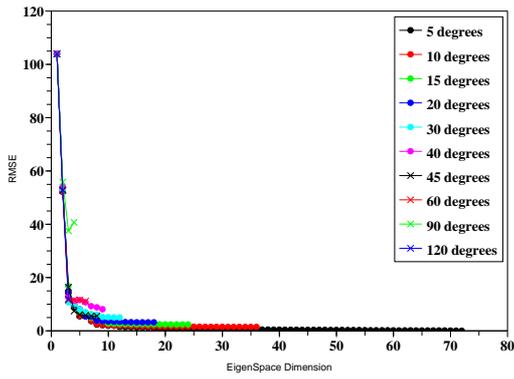
☒ B.8.92: obj92



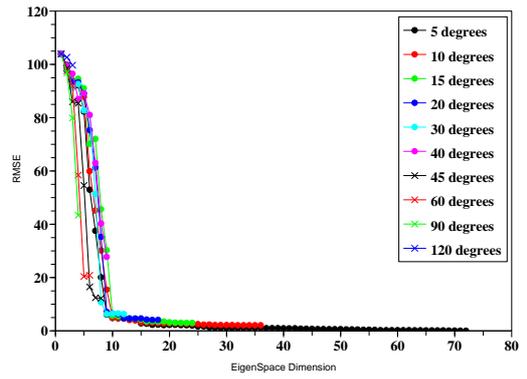
☒ B.8.93: obj93



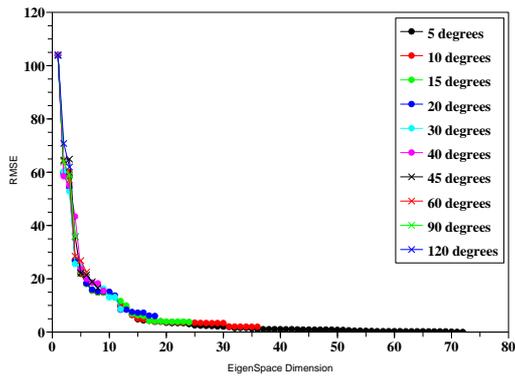
☒ B.8.94: obj94



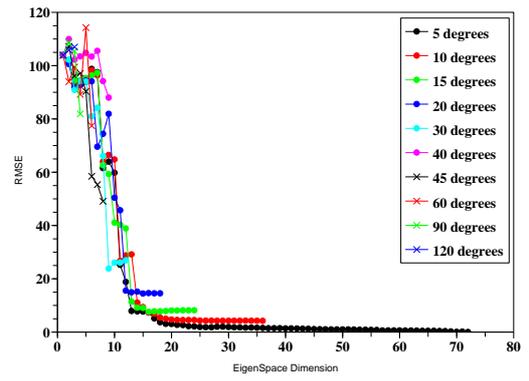
☒ B.8.95: obj95



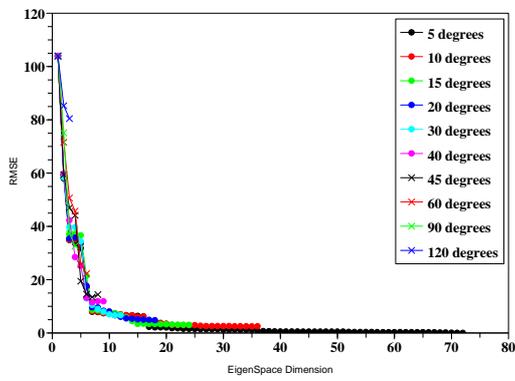
☒ B.8.96: obj96



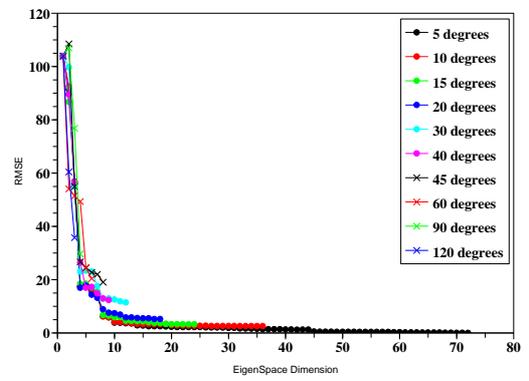
☒ B.8.97: obj97



☒ B.8.98: obj98

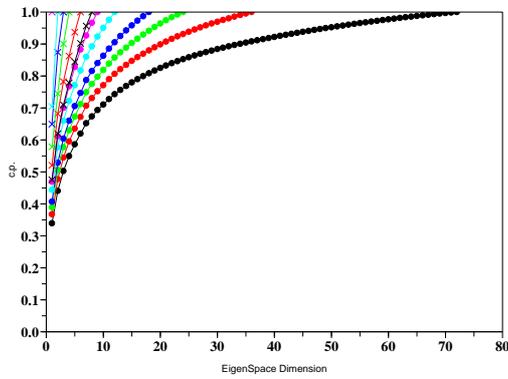


☒ B.8.99: obj99

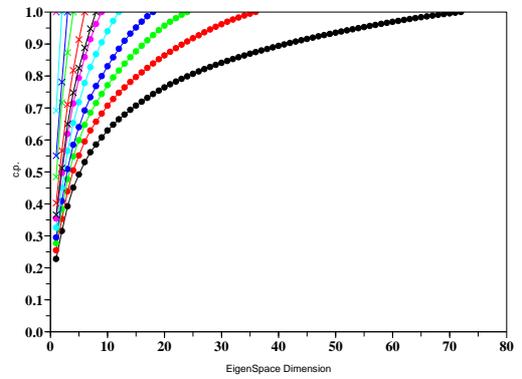


☒ B.8.100: obj100

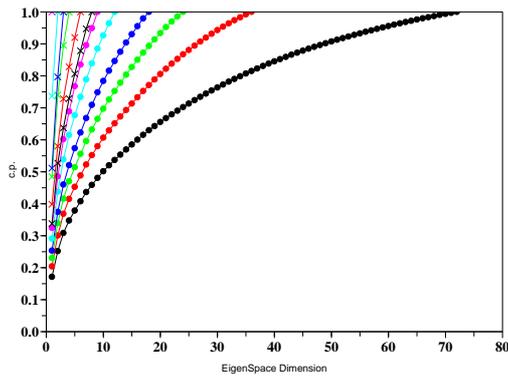
## B.9 累積寄与率 (COIL-20)



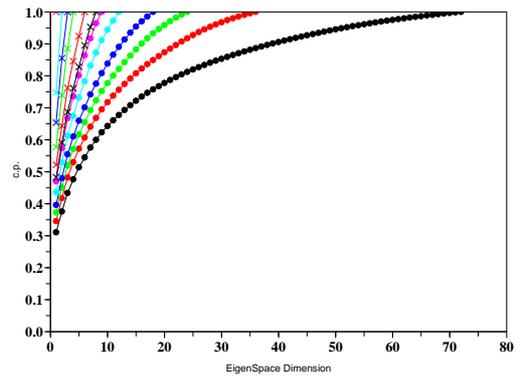
☒ B.9.1: obj1



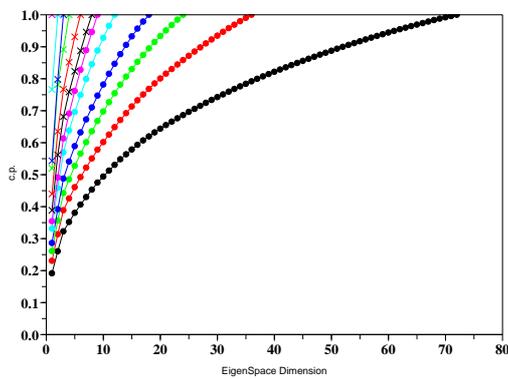
☒ B.9.2: obj2



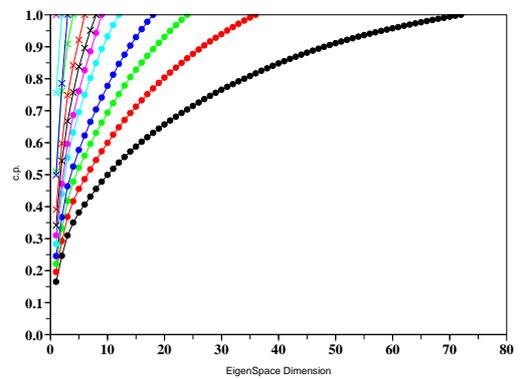
☒ B.9.3: obj3



☒ B.9.4: obj4



☒ B.9.5: obj5



☒ B.9.6: obj6

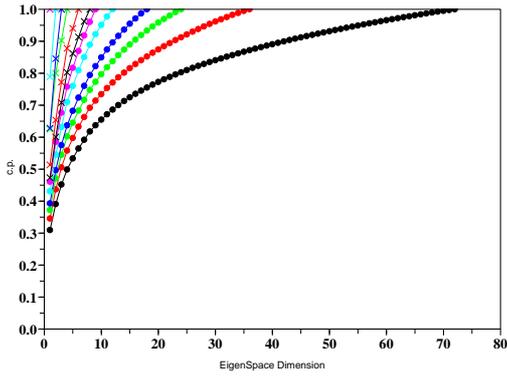


図 B.9.7: obj7

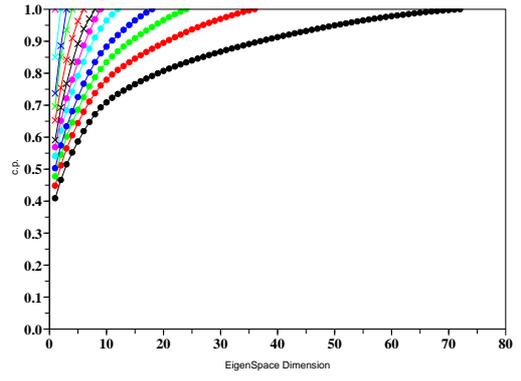


図 B.9.8: obj8

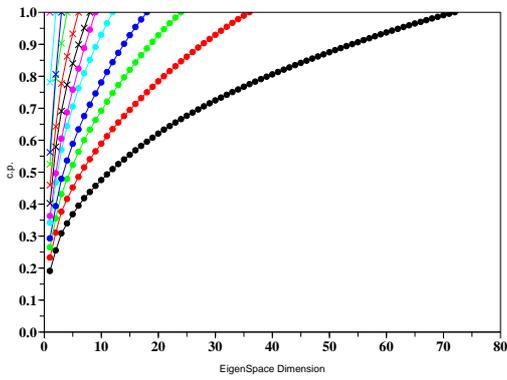


図 B.9.9: obj9

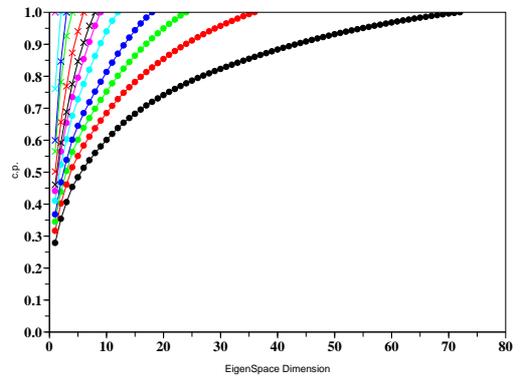


図 B.9.10: obj10

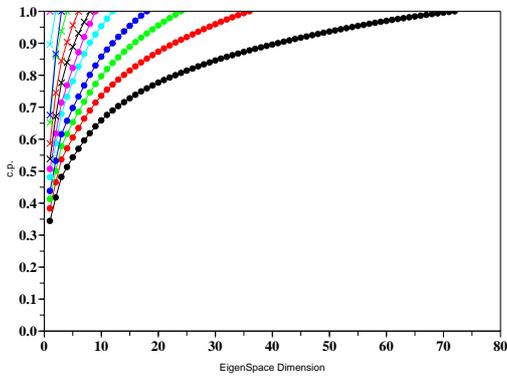


図 B.9.11: obj11

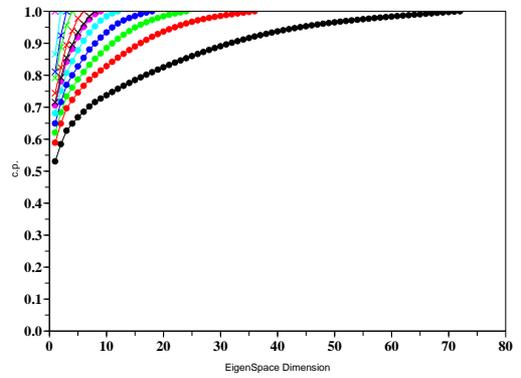


図 B.9.12: obj12

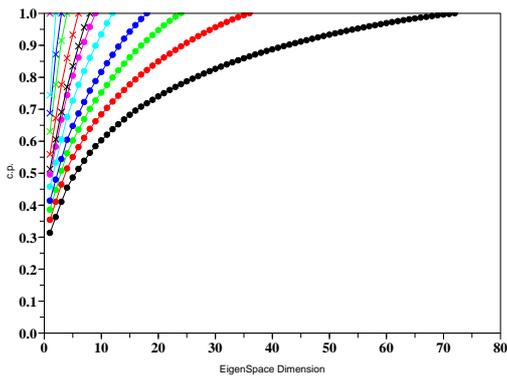


図 B.9.13: obj13

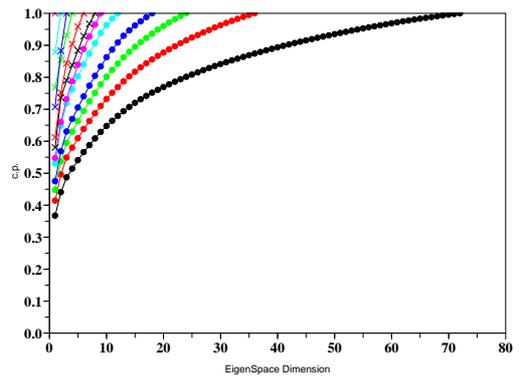
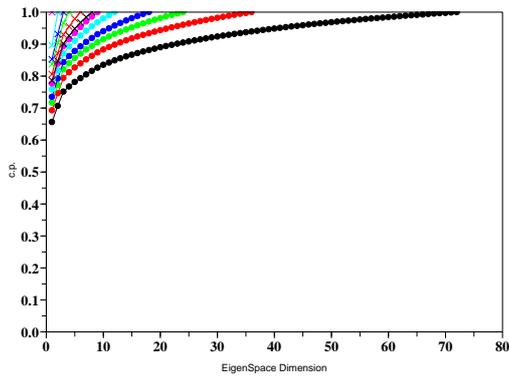
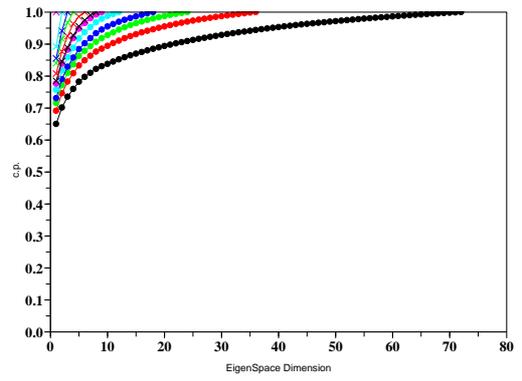


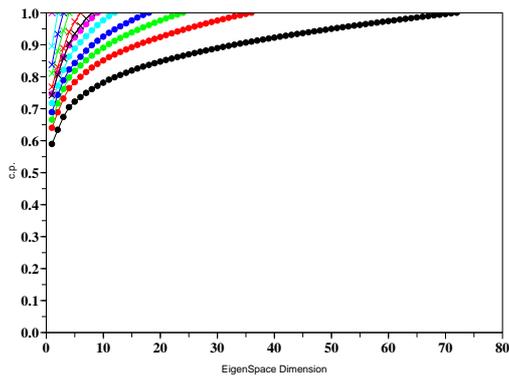
図 B.9.14: obj14



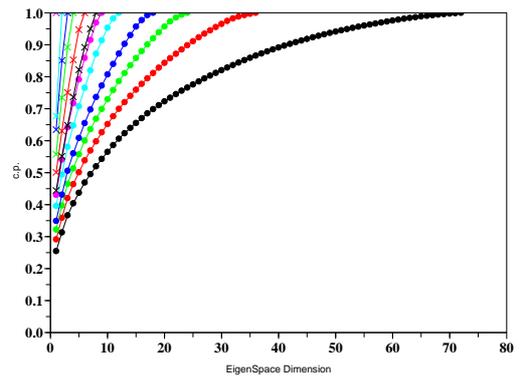
☒ B.9.15: obj15



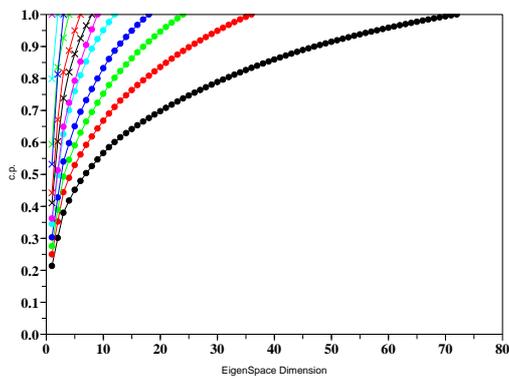
☒ B.9.16: obj16



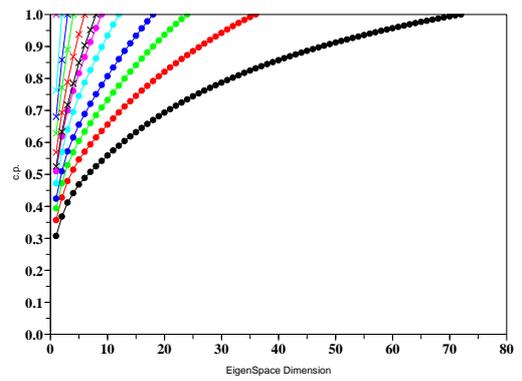
☒ B.9.17: obj17



☒ B.9.18: obj18



☒ B.9.19: obj19



☒ B.9.20: obj20