



J. Korean Soc. Aeronaut. Space Sci. 48(1), 13-21(2020)

DOI:https://doi.org/10.5139/JKSAS.2020.48.1.13

ISSN 1225-1348(print), 2287-6871(online)

코크리깅을 활용한 신속한 유도무기 공력계수 추정

강신성¹, 이경훈²

Rapid Estimation of the Aerodynamic Coefficients of a Missile via Co-Kriging

Shinseong Kang¹ and Kyunghoon Lee²

Department of Aerospace Engineering, Pusan National University

ABSTRACT

Surrogate models have been used for the rapid estimation of six-DOF aerodynamic coefficients in the context of the design and control of a missile. For this end, we may generate highly accurate surrogate models with a multitude of aerodynamic data obtained from wind tunnel tests (WTTs); however, this approach is time-consuming and expensive. Thus, we aim to swiftly predict aerodynamic coefficients via co-Kriging using a few WTT data along with plenty of computational fluid dynamics (CFD) data. To demonstrate the excellence of co-Kriging models based on both WTT and CFD data, we first generated two surrogate models: co-Kriging models with CFD data and Kriging models without the CFD data. Afterwards, we carried out numerical validation and examined predictive trends to compare the two different surrogate models. As a result, we found that the co-Kriging models produced more accurate aerodynamic coefficients than the Kriging models thanks to the assistance of CFD data.

초 록

유도무기의 설계 및 제어에서 6자유도 공력계수의 신속한 추정을 위해 공력계수 데이터에 기반한 예측 모형이 주로 이용된다. 고정확도의 공력계수 예측 모형은 다수의 풍동시험 데이터로 생성할 수 있지만, 이는 많은 시간과 자원을 요구한다. 따라서 본 연구에서는 소수의 풍동시험 데이터를 다수의 전산유체역학 데이터와 혼합한 코크리깅 기법을 활용해 고정확도의 공력계수를 신속하고 효율적으로 예측하고자 한다. 풍동시험과 전산유체역학 데이터를 혼용한 예측 모형의 우수성을 보기 위해, 전산유체역학 데이터 보조의 유무에 따라 두 가지 공력계수 예측 모형을 생성한 후 수치적 검증과 예측 경향성 점검으로 두 모형의 예측 정확도를 비교하였다. 그 결과, 전산유체역학 데이터의 도움 덕분에 코크리깅 모형으로 크리깅 모형보다 더 정확한 공력계수 산출이 가능한 것을 확인하였다.

Key Words : Aerodynamic Coefficient(공력계수), Machine Learning(기계학습), Gaussian Process(가우스 과정), Multi-Fidelity Modeling(다층실도 모형화)

1. 서 론

유도무기 설계 시 공력형상 최적화나 운용 시의

제어에 있어 6자유도 공력계수를 정확하고 신속히 산출하는 것은 중요하다. 공력계수를 얻기 위한 주된 방법으로는 해석적 방법인 전산유체역학과 실험적

† Received : September 2, 2019 Revised : November 7, 2019 Accepted : November 19, 2019

¹ Graduate Student, ² Associate Professor

² Corresponding author, E-mail : aeronova@pusan.ac.kr, ORCID 0000-0003-0709-7442

© 2020 The Korean Society for Aeronautical and Space Sciences

방법인 풍동시험이 있으며, 이들은 상반되고 상보적인 특성이 있다. 전산유체역학은 풍동시험보다 상대적으로 적은 자원과 시간을 소요한다. 하지만 단순화를 위한 여러 가정을 포함한 지배방정식을 풀기 때문에 유도무기의 실제 유동과 차이가 발생한다. 즉, 전산유체역학으로 얻어지는 6자유도 공력계수 데이터의 정확도는 낮다. 반면, 풍동시험은 많은 자원과 시간을 소요하지만 실제 유동 측정을 통해 고정확도의 데이터를 얻을 수 있다.

앞서 언급한 두 가지 방법으로 유도무기의 공력계수를 얻을 수 있지만, 자원과 시간의 한계로 인해 모든 조합의 입력(Input)에 대한 공력계수를 얻는 것은 불가능하다. 이러한 이유로 공력 해석 분야에서는 소수의 데이터로 공력계수 예측 모형을 만드는 대체모형화(Surrogate Modeling) 기법들이 제안되어 많이 쓰이고 있다[1-7]. 다양한 대체모형화 기법 중 가우스 과정 모형(Gaussian Process Model)은 비선형성이 강한 함수에 대해 고전적인 다항식 모형(Polynomial Model)보다 예측 정확도가 동일 표본 대비 더 높아 공력계수 예측 모형에 많이 이용되어 왔다[8-10]. 특히, 공력 해석 분야에서는 입력변수에 대한 구배를 보조변수법(Adjoint Variable Method)으로 쉽게 얻을 수 있기 때문에 구배 보강 크리깅(Gradient-Enhanced Kriging)이 주로 이용되고 있다. 이 방식으로 생성된 공력계수 예측 모형은 구배 기반 최적화 알고리즘에 적합하여 공력형상 최적화에 많이 활용되고 있다[11-13]. 구배 보강 크리깅 외에, 다양한 충실도의 데이터를 혼용하는 코크리깅(Co-Kriging)도 효율적인 공력계수 예측을 위해 사용된다. 예를 들어, 서로 다른 이론을 바탕으로 해석된 데이터를 혼합하거나[3,10,14-17], 전산유체역학에서 유한체적(Finite Volume)의 크기 또는 모형의 충실도를 다르게 사용하여 얻어진 데이터를 혼합하는 것이 있다[13,18-19].

본 연구에서는 6자유도 공력계수 유도무기 공력계수의 신속한 예측을 위해서 코크리깅을 채용한다. 서로 다른 충실도의 전산유체역학 데이터로 코크리깅이 수행된 기존 연구[14,20]와 달리, 전산유체역학과 풍동시험 데이터가 혼합된 공력계수 예측 모형 생성을 목표로 한다. 이 방식은 실제 유동 특성을 보유한 공력계수 예측 모형을 만들 수 있는 이점이 있다. 또한, 전산유체역학 데이터를 보조 데이터로 사용함으로써 적은 수의 풍동시험 데이터만이 사용되므로 자원과 시간을 절약할 수 있다. 전산유체역학 데이터가 보조된 코크리깅 모형의 효과를 살펴보기 위해, 본 연구에서는 풍동시험 데이터만으로 생성된 크리깅 모형을 먼저 생성하고 이를 코크리깅 모형의 정확도와 비교해본다. 모형의 정확도는 수치적 검증과 공력계수 예측 경향성 조사로 사정한다. 추가로, 예측 불확실성(Prediction Uncertainty)을 도출하여 코크리깅 모형의 예측 신뢰도를 살펴본다.

본 논문은 다음과 같이 구성되어 있다. 본론의 첫 번째 절에선 회귀 크리깅(Regression Kriging)과 이를 확장한 회귀 코크리깅의 개념과 수식에 대해서 간략히 설명한다. 이후 결과 및 고찰에서 풍동시험 표본에 대한 크리깅 모형과 코크리깅 모형을 생성하고 이들의 정확도를 앞서 언급한 두 가지 방식으로 비교해본다. 마지막 결론에서 전산유체역학 데이터가 보조된 풍동시험 코크리깅 모형의 이점을 정리하며 논문을 마무리 짓는다.

II. 본 론

2.1 가우스 과정 모형화 기법

2.1.1 회귀 크리깅

측정 잡음(Measurement Noise)을 가지는 풍동시험 공력 데이터의 예측 모형을 만들기 위해 본 논문에서는 회귀 가우스 과정(Regression Gaussian Process)을 사용한다. 회귀 크리깅으로도 불리는 이 기법은 훈련 표본(Training Sample)의 출력(Output)이 입력에 대한 확률 과정(Stochastic Process)의 결과라고 가정하는 것으로 시작한다[21]. 이러한 가정 하에서 출력은 결정론적인 항과 확률론적인 항으로 분리될 수 있다. 수식으로

$$Y(x) = \mu + Z(x) + E(x) \quad (1)$$

와 같이 나타낼 수 있으며, 여기서 x 는 훈련 표본의 입력, $Y(x)$ 는 출력, μ 는 결정론적인 항, $Z(x)$ 는 입력에 대한 확률론적인 항, 그리고 $E(x)$ 는 잡음에 대한 확률론적인 항을 의미한다. 다음 절차로 $Z(x)$ 와 $E(x)$ 항이 평균으로 0, 분산으로 각각 σ^2 과 ν^2 을 가지는 서로 독립인 정규분포를 따른다고 가정한다. 즉, $Z(x) \sim N(0, \sigma^2)$, $E(x) \sim N(0, \nu^2)$ 이다. 결과적으로 정규분포 합의 성질에 의해 훈련 표본 $S_{\text{train}} = \{(x^{(i)}, y^{(i)}) | x^{(i)} \in \mathbb{R}^k, y^{(i)} \in \mathbb{R}, 1 \leq i \leq n\}$ 에 대한 회귀 크리깅 모형은 식 (2)와 같은 정규분포를 따르게 된다.

$$\{Y(x^{(i)})\}_{i=1}^n \sim N(\mu \mathbf{1}_n, \sigma^2 \Psi + \nu^2 I) = N(\mu \mathbf{1}_n, \sigma^2 (\Psi + \lambda I)), \quad (2)$$

여기서 $\mathbf{1}_n \in \mathbb{R}^n$ 은 모든 원소가 1인 열벡터, $I \in \mathbb{R}^{n \times n}$ 은 단위행렬이며, $\lambda = \nu^2 / \sigma^2$ 는 잡음에 대한 초모수(Hyperparameter)이다. 입력 간의 상관행렬(Correlation Matrix) $\Psi \in \mathbb{R}^{n \times n}$ 의 각 원소는 다변량 정규분포 식에 의해

$$\Psi_{ij}(x^{(i)}, x^{(j)}) = \prod_{l=1}^k \exp(-\theta_l (x_l^{(i)} - x_l^{(j)})^2) \quad (3)$$

으로 계산된다. 식 (3)의 θ 는 입력변수에 대한 초모

수로, 입력변수가 출력에 영향을 미치는 정도, 즉, 민감도(Sensitivity)라고 할 수 있다. 회귀 가우스 과정의 모수 및 초모수는 로그 우도 함수(Log-likelihood Function) $\ell(\mu, \sigma, \lambda, \theta)$ 가 최대가 되도록 $\hat{\mu}$, $\hat{\sigma}$, $\hat{\lambda}$, $\hat{\theta}$ 을 추정하는 방식인 최대우도추정(maximum likelihood estimation, MLE)으로 결정될 수 있다. 로그 우도 함수는 식 (2)의 정규분포로부터 식 (4)와 같이 유도된다.

$$\ell(\mu, \sigma, \lambda, \theta) = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln(\sigma^2) - \frac{1}{2} \ln |\Psi + \lambda I| - \frac{1}{2\sigma^2} (y - \mu \mathbf{1}_n)^\top (\Psi + \lambda I)^{-1} (y - \mu \mathbf{1}_n), \quad (4)$$

여기서 $y = [y^{(1)}, y^{(2)}, \dots, y^{(n)}]^\top \in \mathbb{R}^n$ 는 훈련 표본의 출력을 원소로 가지는 열벡터이다. 식 (4)에서 최대우도 추정으로 모수 $\hat{\mu}$ 와 $\hat{\sigma}$ 를 각각 구하면

$$\hat{\mu} = \frac{\mathbf{1}_n^\top \Psi^{-1} y}{\mathbf{1}_n^\top \Psi^{-1} \mathbf{1}_n}, \quad \hat{\sigma}^2 = \frac{(y - \mu \mathbf{1}_n)^\top (\Psi + \lambda I)^{-1} (y - \mu \mathbf{1}_n)}{n} \quad (5)$$

이다. 이들을 식 (4)에 다시 대입하여 정리하면, 초모수 λ 와 θ 만을 가지는

$$\ell(\lambda, \theta) \approx -\frac{n}{2} \ln(\hat{\sigma}^2) - \frac{1}{2} \ln |\Psi + \lambda I| \quad (6)$$

을 얻을 수 있다. 식 (5), (6)은 μ , σ , λ , θ 가 서로 연관(Coupling)되어 있다. 따라서 식 (6)이 목적함수(Objective Function), 초모수의 범위가 부가적 제약 조건(Side-Constraint)으로 사용되는 최적화 과정을 거쳐 $\hat{\lambda}$, $\hat{\theta}$ 을 먼저 도출한다. 그 후 식 (5)로 $\hat{\mu}$, $\hat{\sigma}$ 를 계산하여 회귀 크리깅 모형을 얻는다.

2.1.2 회귀 코크리깅

코크리깅은 서로 다른 충실도의 표본을 사용하는 다충실도 모형화(Multi-Fidelity Modeling)의 한 종류이다. 이 기법은 자원과 시간을 많이 소요하는 고충실도 표본을 적게 사용하고, 부족한 고충실도 표본을 쉽게 얻을 수 있는 다수의 저충실도 표본으로 보충하여 고충실도 모형을 생성하므로 실용적이다.

코크리깅 과정은 크게 두 단계로 나뉜다. 먼저 저충실도 표본만을 사용하여 크리깅 모형

$$Y_c(x_c) = \mu_c + Z_c(x_c) + E_c(x_c) \quad (7)$$

을 생성한다. 그리고서 저충실도 모형 $Y_c(x)$ 와 고충실도 크리깅 모형 $Y_e(x)$ 의 관계가

$$Y_e(x_e) = \rho Y_c(x_c) + Y_d(x_c, x_e) \quad (8)$$

로 표현된다고 가정한다. 여기서 $Y_d(x)$ 는 차이 모형이며, ρ 는 축척 인자로서 값이 크면 고충실도 모형이

저충실도 모형의 경향성에 큰 영향을 받게 된다. 식 (8)은 $\rho Y_c(x_c)$ 를 좌측으로 이항하여 차이 모형에 대한 식으로 표현될 수 있으며, 차이 모형이 저충실도와 고충실도 표본에 대해서 크리깅 모형이라고 상정하면

$$Y_d(x_c, x_e) = Y_e(x_e) - \rho Y_c(x_c) = \mu_d + Z_d(x_c, x_e) + E_d(x_c, x_e) \quad (9)$$

와 같은 식을 얻는다. 즉, 코크리깅에서는 저충실도 크리깅 모형과 차이 크리깅 모형을 각각 생성한 후 조합함으로써 고충실도 크리깅 모형을 만든다. 두 모형의 모수 및 초모수는 크리깅 모형의 모수 및 초모수를 결정하는 동일한 최적화 과정을 통해 추정된다. 단, 차이 크리깅 모형 생성을 위해서는 식 (6)에 축척 인자가 추가된 식을 사용하여 모수 및 초모수를 추정한다.

2.2 결과 및 고찰

2.2.1 다충실도 공력계수 모형화 개요

공력계수 예측 모형을 생성하기 위한 공력 데이터는 측방화염이 없는 유도무기의 공력계수 데이터로써, 저충실도의 전산유체역학 데이터와 고충실도의 풍동시험 데이터가 있다. 여기서 풍동시험 데이터는 후처리(Post-Processing)로 측정 잡음을 일부 제거한 데이터이다. 각각의 데이터는 입력변수로 마하수 M , 경사각 ϕ , 받음각 α 를 가지며 출력변수로 Fig. 1과 같이 공기역학적 힘 계수 C_x , C_y , C_z 와 모멘트 계수 C_l , C_m , C_n 을 가진다. 총 표본 수는 각각 60개와 45개대로써, Fig. 2의 입력변수 간격으로 완전요인배치법(Full Factorial Design)을 수행한 결과이다. 본 연구에서는 총 45개의 풍동시험 데이터에서 부분집합 표본추출(Subset Sampling)을 통해 34개(76%)의 훈련 표본을 생성하고, 나머지 11개(24%)는 모형 검증을 위한 시험 표본(Testing Sample)으로 사용한다. 입력과 출력의 정확한 값과 유도무기의 종류는 군사보안 문제로 명시할 수 없어, 본 논문에 포함된 모든 그래프의 축 값을 제거하였다.




Fig. 1. Six-DOF aerodynamic coefficients of a four-finned missile

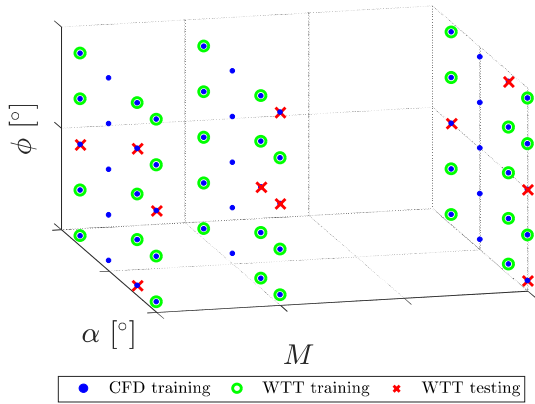


Fig. 2. Three-dimensional scatter plot of CFD and WTT input samples

본 연구에서는 i) 풍동시험 훈련 표본 34개만이 이용된 크리깅 모형(이하 WTT 크리깅 모형)과 ii) 풍동시험 훈련 표본 34개에 전산유체역학 데이터 60개가 보조된 코크리깅 모형(이하 WTT 코크리깅 모형)을 생성하여 두 모형의 6자유도 공력계수 예측 정확도를 비교하여 본다. 정확도 비교 방법으로는 수치적 검증 을 통한 정량적 방법과 입력변수의 변화에 따른 공력 계수 예측 그래프를 통한 정성적 방법을 사용한다.

다중실도 공력계수 모형화는 Intel(R) Xeon(R) CPU E5-2630 v3 @ 2.4 GHz, 32 GB RAM, 8 cores 환경에서 직접 제작한 매트랩 코드로 수행되었다. 초모수 탐색 범위는 Table 1에 요약되어 있으며, 입자 군 최적화(Particle Swarm Optimization, PSO)와 순차적 2차 계획법(Sequential Quadratic Programming, SQP)을 함께 사용한 하이브리드 최적화 방식으로 초모수를 추정하였다.

2.2.2 WTT 크리깅 모형

다중실도 모형화에 앞서 WTT 크리깅 모형을 생성하였다. 이 모형은 풍동시험 데이터의 특성 파악과 WTT 코크리깅 모형과의 비교에 사용되었다.

Table 1. Hyperparameter search bounds for Kriging and co-Kriging modeling (base-10 logarithmic scale)

Output	θ	λ	ρ
C_y	[-7.0, 3.0]	[-4.0, 1.0]	[-3.0, 0.5]
C_z	[-2.0, 2.0]	[-4.0, 1.0]	[-7.0, -5.0]
C_m	[-2.0, 2.0]	[-4.0, 1.0]	[-7.0, -5.0]
C_n	[-7.0, 3.0]	[-4.0, 1.0]	[-3.0, 0.5]
C_x	[-0.3, 0.3]	[-4.0, -3.0]	[-0.5, 0.0]
C_l	[-0.8, 0.8]	[-3.0, -1.5]	[-1.0, -0.5]

Table 2. Estimated hyperparameters for input variables in the WTT Kriging model (base-10 logarithmic scale)

Output	$\hat{\theta}_1 (M)$	$\hat{\theta}_2 (\phi)$	$\hat{\theta}_3 (\alpha)$
C_y	-7.0000	-0.7521	-0.8792
C_z	-2.0000	-0.9489	-0.4312
C_m	-2.0000	-0.9339	-0.3709
C_n	-2.0000	-0.7954	-0.9581
C_x	-7.0000	-0.1528	-0.3000
C_l	0.1510	0.8000	-0.3997

풍동시험 훈련 표본 34개로 생성된 크리깅 모형의 초모수 추정 결과를 Table 2에 정리하였다. 2.1.1절에서 언급했듯이, 추정된 초모수의 크기는 입력변수가 WTT 크리깅 모형에 영향을 미치는 정도이다. Table 3의 입력변수에 대한 초모수의 크기를 비교해보면 C_y, C_n, C_x, C_l 은 경사각 ϕ , C_z 와 C_m 은 받음각 α 에 가장 많은 영향을 받는 것으로 나타났다.

다음으로 생성한 WTT 크리깅 모형을 정량적으로 검증해보았다. 수치검증에 사용한 척도는 결정계수(Coefficient of Determination), 평균 상대 절대 오차(Mean Absolute Relative Error), 최대 상대 절대 오차(Maximum Absolute Relative Error)이며 각각 식 (10)-(12)로 계산된다.

$$R^2 = 1 - \frac{\sum_{i=1}^k (y_i - \hat{y}_i)^2}{\sum_{i=1}^k (y_i - \bar{y})^2}, \quad (10)$$

$$\text{MARE} = \frac{1}{k} \sum_{i=1}^k |(y_i - \hat{y}_i)/y_i|, \quad (11)$$

$$\text{maxARE} = \max_{1 \leq i \leq k} |(y_i - \hat{y}_i)/y_i|, \quad (12)$$

여기서 y 는 표본 값, \hat{y} 는 모형 예측값, \bar{y} 는 표본 값의 평균을 의미한다. 결정계수는 모형의 전반적인 정확도를 수치적으로 나타낼 수 있는 척도로 0과 1 사이의 값을 가지며, 1에 가까울수록 모형이 표본에 맞게 잘 생성되었다고 할 수 있다. 나머지 두 척도는 0에 가까울수록 표본 값과 모형 예측값의 오차가 작다고 할 수 있다. 모든 공력계수 예측 모형은 훈련 표본 34개에 대해서 R^2 가 0.99 이상, MARE와 maxARE는 0.12 이하였으므로 훈련 표본에 부합하는 모형이라고 할 수 있다. 시험 표본 11개에 대한 검증 결과는 Table 3에 요약되어 있다. 결정계수가 0.97 이상인 C_y, C_z, C_m, C_n, C_x 예측 모형은 MARE

Table 3. Numerical validation results of the WTT Kriging model for testing samples

Output	R^2	MARE	maxARE
C_y	0.9902	0.0668	0.1228
C_z	0.9963	0.0310	0.0540
C_m	0.9970	0.0284	0.0474
C_n	0.9908	0.0696	0.1206
C_x	0.9717	0.0220	0.1230
C_l	0.8799	0.3038	0.3038

와 maxARE도 0.02-0.12인 것을 볼 때 정확도 높은 모형이었다. 반면, C_l 은 결정계수와 maxARE가 각각 0.88과 0.30인 것을 보아, 모형의 전반적인 정확도가 다소 떨어지며 오차가 큰 부분이 존재한다는 것을 알 수 있다.

Table 3의 검증 결과는 시험 표본 11개에 대해서만 검증한 결과이며, 이 개수는 크리깅 모형의 정확도를 완벽히 판단하기에 다소 적다. 다시 말해서, 앞서 생성한 크리깅 모형이 소수의 시험 표본만을 잘 예측하

면 수치적 검증 결과는 좋지만, 시험 표본 이외의 전반적인 예측 결과에는 오류가 있을 수 있다. 따라서 우리는 입력변수의 변화에 대해 WTT 크리깅 모형의 예측 결과를 그래프로 나타내 모형의 전체적인 경향성을 조사하여 정확도를 재점검하였다. Figs. 3, 4는 각각 경사각과 받음각의 변화에 따른 6자유도 공력계수 예측 결과를 나타낸다. Fig. 3에서 서로 다른 색의 실선은 각기 다른 받음각에서의 결과를 나타내며, Fig. 4에서는 다른 경사각에서의 결과를 나타낸다. 또한, Figs. 3, 4에서 모든 그래프는 마하수를 특정값으로 고정하였을 때의 결과이다. Figs. 3, 4의 C_y, C_z, C_m, C_n 그래프를 보면, 훈련 표본과 시험 표본을 잘 따르고 있을 뿐만 아니라 전체적인 경향성도 매끄러운 것을 볼 수 있다. 또한, C_l 의 수치적 검증 결과는 다소 낮았지만 전반적인 예측 결과는 우수하다. 이것으로 보아 C_l 의 결정계수가 낮은 원인은 소수의 시험 표본에서 오차가 크게 났던 것이 원인으로 추측된다. 이와는 반대로 C_x 크리깅 모형의 수치적 검증 결과는 0.97로 우수하게 나왔지만, 표본과 예측 그래프의 경향성이 달라 보이는 문제점이 보인다. Fig. 3의 C_x 그래프에서 검은색 점과 실선을 보면, 표본들의 경향성은 일렬로 추정되지만 예측 그래프는 4차 다항함수와

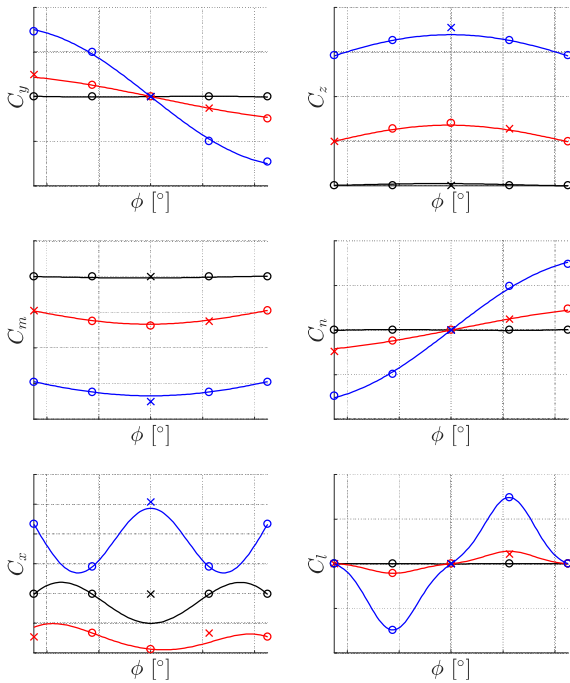


Fig. 3. Aerodynamic coefficients estimated by Kriging for the changes of a bank angle. The circled and cross markers denote training and testing samples, respectively. The different colors for the lines and the markers indicate disparate angles of attack.

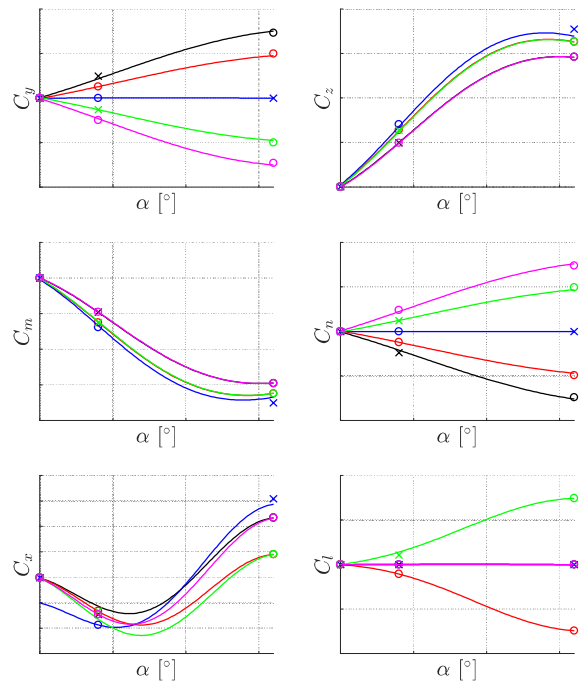


Fig. 4. Aerodynamic coefficients estimated by Kriging for the changes of an angle of attack. The circled and cross markers denote training and testing samples, respectively. The different colors for the lines and the markers indicate disparate bank angles.

같은 곡선의 형태로 나타났다. 예측 그래프의 경향성이 실제 풍동시험 데이터의 경향성을 나타낸 것인지 판단하기 위해서는 C_x 데이터를 추가해야 할 것이다.

2.2.3 WTT 코크리깅 모형

다음으로 WTT 크리깅 모형에 전산유체역학 데이터 60개를 보조하여 WTT 코크리깅 모형을 생성하였다. 생성된 모든 WTT 코크리깅 모형은 훈련 표본 34개에 대해서 R^2 는 0.99 이상, MARE는 0.04 이하, maxARE는 0.11 이하로, 훈련 표본에 잘 들어맞는 모형이었다. 시험 표본에 대한 수치적 검증 결과는 Table 4에 정리되어 있다. Table 4를 WTT 크리깅 모형의 검증 결과인 Table 3과 비교해보면, C_z 와 C_m 을 제외한 나머지 공력계수의 예측 모형이 개선된 것을 알 수 있다. 특히, C_x 와 C_l 의 경우에는 WTT 크리깅 모형의 결정계수인 0.97과 0.88에 비해서 WTT 코크리깅 모형의 결정계수는 0.99와 0.93으로 확연히 개선되었다. 정확도가 오히려 감소한 C_z 와 C_m 의 경우에도 국부적으로 오차가 조금 증가하였을 뿐 R^2 는 변하지 않았다. 이는 C_z 와 C_m 풍동시험 데이터로 정확도가 높은 WTT 크리깅 모형이 만들어졌고, 이후 저충실도의 전산유체역학 데이터로 우수한 모형을 보조하였기 때문에 일부 시험 표본에서 오차가 상승한 것으로 추측된다.

WTT 크리깅 모형의 검증 절차와 마찬가지로, 수치적 검증 이후에 공력계수 그래프를 통한 정성적 검증을 수행하였다. Figs. 5, 6은 각각 경사각과 받음각의 변화에 따른 6자유도 공력계수를 WTT 코크리깅 모형으로 예측한 결과를 나타낸다. Figs. 5, 6에서 사용된 색과 기호의 의미는 Figs. 3, 4와 동일하며, 1σ (68.27%)의 예측 불확실성을 회색 영역으로 추가하였다. WTT 크리깅 모형의 그래프와 비교하여 보았을 때 가장 큰 차이를 보이는 것은 C_x 의 예측 결과이다. 앞서 의문점이 있었던 Fig. 3의 검은색 C_x 예측 그래프는 코크리깅 덕분에 표본의 경향성과 유사하게 거의 직선이 된 것을 Fig. 5에서 볼 수 있다.

Table 4. Numerical validation results of the WTT co-Kriging model for testing samples

Output	R^2	MARE	maxARE
C_y	0.9904	0.0653	0.1209
C_z	0.9963	0.0315	0.0560
C_m	0.9970	0.0290	0.0496
C_n	0.9910	0.0681	0.1189
C_x	0.9905	0.0158	0.0444
C_l	0.9337	0.1885	0.1885

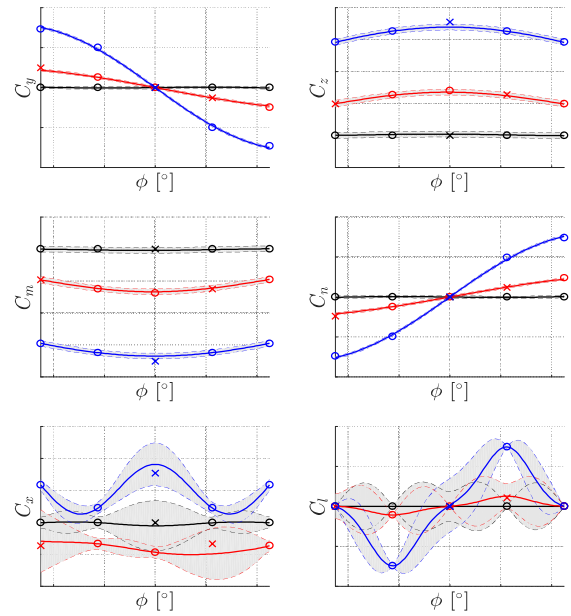


Fig. 5. Aerodynamic coefficients estimated by co-Kriging for the changes of a bank angle. The circled and cross markers denote training and testing samples, respectively. The different colors for the lines and the markers indicate disparate angles of attack. Gray areas show 1σ (68.27%) prediction uncertainties.

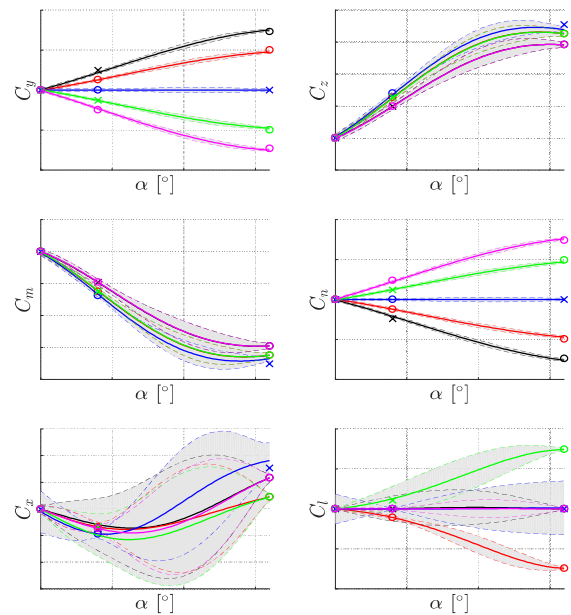


Fig. 6. Aerodynamic coefficients estimated by co-Kriging for the changes of an angle of attack. The circled and cross markers denote training and testing samples, respectively. The different colors for the lines and the markers indicate disparate bank angle. Gray areas show 1σ (68.27%) prediction uncertainties.

또한, Fig. 4의 C_x 그래프에서 파란색 선은 세로 축 위에 있는 시험 표본을 잘 예측하지 못하였지만, Fig. 6에서는 잘 예측하였다.

WTT 코크리깅 모형의 우수성을 정성적으로 더 확인해 보기 위해, 크리깅과 코크리깅 모형의 수치적 검증 결과 차이가 뚜렷했던 C_x , C_l 예측 결과를 Fig. 7과 같이 3차원 곡면 그래프로 나타내었다. Figs. 3-6에서 하나의 마하수 M_1 에 대한 결과만 보았었지만, Fig. 7에는 이와 상이한 마하수 M_2 와 M_3 에 대한 결과도 추가하였다. 빨간색 점선 곡면은 WTT 크리깅 모형, 파란색 실선 곡면은 WTT 코크리깅 모형을 나타낸다. 먼저 C_l 예측 곡면 그래프를 보면, WTT 크리깅과 코크리깅 모형이 유사하였으며 두 모형이 모두 표본을 잘 따라가는 것처럼 보인다. 이는 크리깅 모형의 R^2 인 0.8799보다 코크리깅 모형의 R^2 가 0.9337로써 코크리깅 모형의 수치적 검증결과가 우수했다는 것과 대조된다. 이런 결과가 나온 원인은 C_l 값이 평균적으로 10^{-2} 이하였기 때문이었다. 다시 말해서, 값이 매우 작으므로 예측값이 표본과 조금이라도 차이가 있으면 수치적 검증결과는 크게 나빠지지만, 공력계수 예측 그래프를 시각적으로 확인해보면 표본을 잘 따라가는 것처럼 보이게 되는 것이다. 다음으로 Fig. 7의 C_x 예측 곡면 그래프는 C_l 와 달리

코크리깅 모형이 크리깅 모형보다 예측 정확도가 높은 것을 확연히 보여준다. 앞선 Figs. 3-6에서 확인할 수 있었던 마하수 M_1 에서의 코크리깅 모형의 정확도 우수성 외에, Fig. 7의 점 (A)와 (B)를 보면 M_2 와 M_3 에서도 코크리깅 모형이 크리깅 모형보다 시험 표본 예측을 잘 하는 것을 볼 수 있다.

정량적 검증 결과인 Tables 3, 4와 정성적 검증 결과인 Figs. 3-7을 통해, WTT 코크리깅 모형이 WTT 크리깅 모형보다 예측 정확도가 더 우수함을 알 수 있었다. 특히, C_x 와 C_l 의 공력계수 예측 정확도를 개선시키는데서 코크리깅이 효과적이었다. 그렇지만, Figs. 5, 6의 예측 불확실성 영역을 보았을 때 C_z , C_m , C_x , C_l 모형의 신뢰성은 부족해 보인다. Fig. 6의 C_z 와 C_m 예측 그래프를 보면, 받음각의 변화에 대해서 예측 불확실성 영역이 넓다. 심지어 C_x 와 C_l 은 받음각뿐만 아니라 경사각의 변화에 대해서도 매우 큰 예측 불확실성을 가지는 것을 Figs. 5, 6에서 볼 수 있다. 따라서 코크리깅을 통해 6자유도 공력계수 예측 모형의 정확도는 높일 수 있었지만, 모형의 신뢰성을 향상하기 위해선 C_z , C_m , C_x , C_l 의 받음각 변화에 대한 데이터, 그리고 C_x , C_l 의 경사각 변화에 대한 데이터가 더 필요하다고 판단된다.

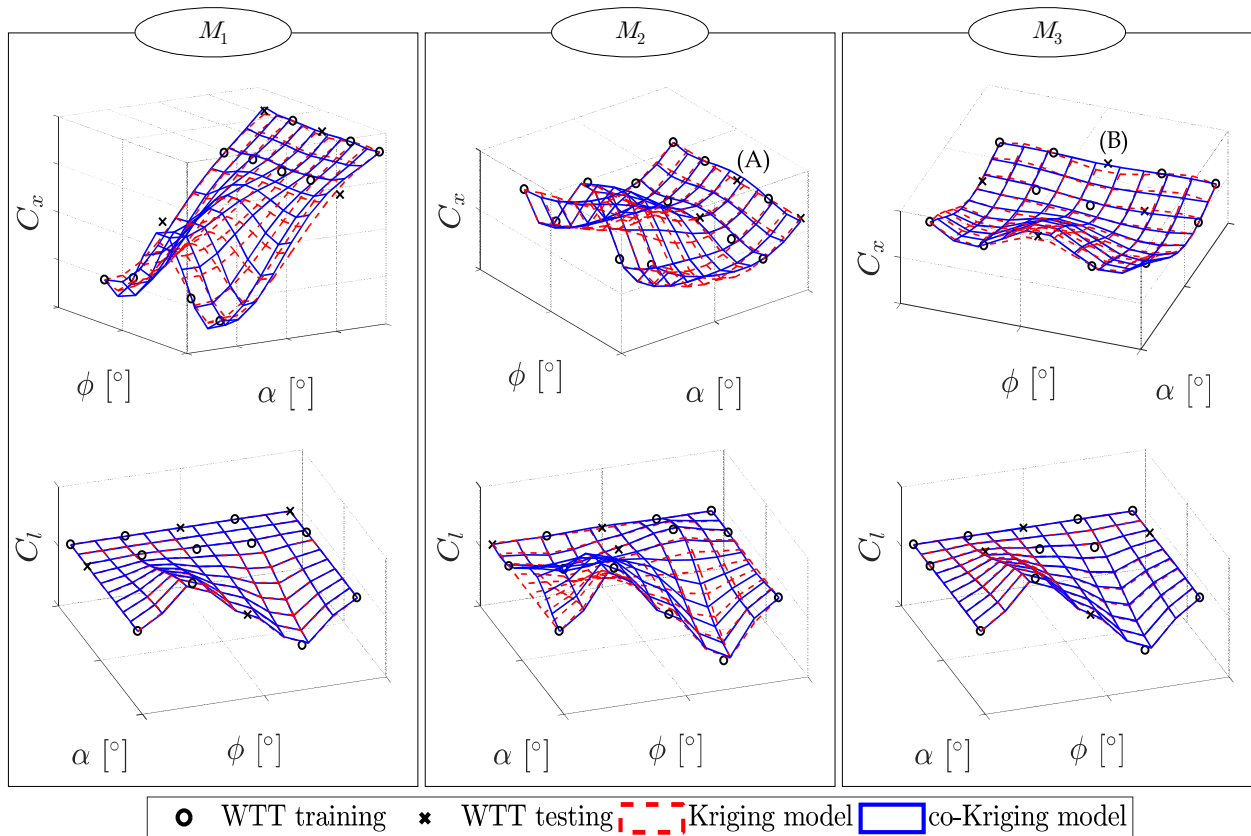


Fig. 7. Comparison of C_x and C_l estimated by Kriging and co-Kriging

III. 결 론

본 연구에서는 측방화염이 없는 유도무기의 풍동 시험으로부터 얻어지는 고충실도의 6자유도 공력계수의 신속한 예측을 목표로 하였다. 이를 위해 회귀 가우스 과정인 크리깅과 코크리깅을 통해 6자유도 공력계수 예측 모형을 생성하였다. 그런 다음 풍동 시험 데이터로만 생성된 크리깅 모형과 전산유체역학 데이터가 보조되어 생성된 코크리깅 모형의 예측 정확도를 정량적, 정성적으로 비교해보았다. 결과적으로, C_y , C_z , C_m , C_n 은 풍동 시험 데이터만으로도 매우 높은 정확도의 크리깅 모형이 만들어져 코크리깅의 이점을 보기 어려웠다. 반면, C_x 와 C_l 의 코크리깅 예측 모형은 크리깅 예측 모형 대비, maxARE는 각각 3.90%, 37.95% 감소하였고 결정계수는 각각 1.93%, 6.11% 증가하였다. 그러므로 풍동 시험 데이터에 전산 유체역학 데이터를 보조하여 코크리깅을 사용한다면, C_x 와 C_l 의 국부적인 오차를 줄여 예측 모형의 전반적인 정확도 향상이 가능하다는 것을 알 수 있었다. 하지만 풍동 시험 데이터에 전산유체역학 데이터를 보조하였더라도, 입력 범위에 비해 두 종류의 데이터의 수가 적어 C_z , C_m , C_x , C_l 예측 모형의 신뢰도는 다소 낮았다. 그러므로 이 네 가지 공력계수 예측 모형의 신뢰성을 높이기 위해선, 차후 예측 불확실성이 넓은 영역에 풍동 시험 또는 전산유체역학 데이터를 추가해야 할 것이다.

후 기

본 연구는 2019년도 정부(과학기술정보통신부)와 2016년도 교육부 재원으로 한국연구재단(No. 2019R1A5A6099595)과 기초연구사업(No. 2016R1D1A1B03930126)의 지원을 받아 수행된 연구로, 이에 감사드립니다. 또한 국방과학연구소 지원에 의한 과제(UE171036CD)와 2017년도 정부(산업통상자원부)의 재원으로 한국산업기술진흥원의 지원을 받아 수행된 연구(N0002431, 2017년 산업전문인력역량강화사업)로, 이에 감사드립니다.

References

- 1) Vidanović, N., Rašuo, B., Kastratović, G., Maksimović, S., Ćurčić, D., and Samardžić, M., "Aerodynamic-Structural Missile Fin Optimization," *Aerospace Science and Technology*, Vol. 65, 2017, pp. 26~45.
- 2) Ha, H., Oh, S., and Yee, K., "Feasibility Study of Hierarchical Kriging Model in the Design

Optimization Process," *Journal of the Korean Society for Aeronautical and Space Sciences*, Vol. 42, No. 2, 2014, pp. 108~118.

- 3) Kontogiannis, S. G., Demange, J., Kipouros, T., and Savill, A. M., "A Comparison Study of Two Multifidelity Methods for Aerodynamic Optimization," *In 2018 AIAA/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference*, January 2018, pp. 0415-1~16.

- 4) Jouhaud, J. C., Sagaut, P., and Labeyrie, B., "A Kriging Approach for CFD/Wind-tunnel Data Comparison," *Journal of Fluids Engineering*, Vol. 128, No. 4, 2006, pp. 847~855.

- 5) Yondo, R., Andres, E., and Valero, E., "A Review on Design of Experiments and Surrogate Models in Aircraft Real-Time and Many-Query Aerodynamic Analyses," *Progress in Aerospace Sciences*, Vol. 96, 2018, pp. 23~61.

- 6) Yim, J., Lee, B. J., and Kim, C., "Exploring Multi-Stage Shape Optimization Strategy of Multi-Body Geometries Using Kriging-Based Model and Adjoint Method," *Computers & Fluids*, Vol. 68, pp. 71~87.

- 7) Kang, K. T., and Lee, S., "Modeling and Assessment of Jet Interaction Database for Continuous-Type Side Jet," *Journal of Spacecraft and Rockets*, Vol. 54, No. 4, 2017, pp. 916~929.

- 8) Simpson, T., Mistree, F., Korte, J., and Mauery, T., "Comparison of Response Surface and Kriging Models for Multidisciplinary Design Optimization," *In 7th AIAA/USAF/NASA/ISSMO Symposium on Multidisciplinary Analysis and Optimization*, September 1998, pp. 4755-1~11.

- 9) Ahmed, M. Y. M., and Qin, N., "Comparison of Response Surface and Kriging Surrogates in Aerodynamic Design Optimization of Hypersonic Spiked Blunt Bodies," *In 13th International Conference on Aerospace Sciences and Aviation Technology*, May 2009, pp. AE-15-1~17.

- 10) Sun, X., Ge, J., Yang, T., Xu, Q., and Zhang, B., "Multifidelity Multidisciplinary Design Optimization of Integral Solid Propellant Ramjet Supersonic Cruise Vehicles," *International Journal of Aerospace Engineering*, 2019, pp. 5192424-1~18.

- 11) Xuan, Y., Xiang, J., Zhang, W., and Zhang, Y., "Gradient-Based Kriging Approximate Model and Its Application Research to Optimization Design," *Science in China Series E: Technological Sciences*, Vol. 52, No. 4, 2009, pp. 1117~1124.

- 12) Han, Z. H., Görtz, S., and Zimmermann, R.,

"Improving Variable-Fidelity Surrogate Modeling via Gradient-Enhanced Kriging and a Generalized Hybrid Bridge Function," *Aerospace Science and Technology*, Vol. 25, No. 1, 2013, pp. 177~189.

13) Jo, Y., and Choi, S., "Variable-Fidelity Aerodynamic Design Using Gradient-Enhanced Kriging Surrogate Model with Regression," *In 52nd Aerospace Sciences Meeting*, January 2014, pp. 0900-1~29.

14) Vanderwyst, A., Shelton, A., and Martin, C. L., "A Computationally Efficient, Multi-Fidelity Assessment of Jet Interactions for Highly Maneuverable Missiles," *In 34th AIAA Applied Aerodynamics Conference*, June 2016, pp. 4333-1~11.

15) Han, Z., Zimmerman, R., and Görtz, S., "Alternative Cokriging Method for Variable-Fidelity Surrogate Modeling," *AIAA journal*, Vol. 50, No. 5, pp. 1205~1210.

16) Toal, D. J. J., and Keane, A. J., "Efficient Multipoint Aerodynamic Design Optimization via Cokriging," *Journal of Aircraft*, Vol. 48, No. 5, 2011, pp. 1685~1695.

17) Da Ronch, A., Ghoreyshi, M., and Badcock, K. J., "On the Generation of Flight Dynamics Aerodynamic Tables by Computational Fluid Dynamics," *Progress in Aerospace Sciences*, Vol. 47, No. 8, 2011, pp. 597~620.

18) Zhou, Q., Wang, Y., Choi, S. K., Jiang, P., Shao, X., and Hu, J., "A Sequential Multi-Fidelity Metamodeling Approach for Data Regression," *Knowledge-Based Systems*, Vol. 134, 2017, pp. 199~212.

19) Yamazaki, W., and Mavriplis, D. J., "Derivative-Enhanced Variable Fidelity Surrogate Modeling for Aerodynamic Functions," *AIAA journal*, Vol. 51, No. 1, 2012, pp. 126~137.

20) Srinivasan, M., Whittecar, W., Edwards, S., and Mavris, D., "Creation of a Rapid High-Fidelity Aerodynamics Module for a Multidisciplinary Design Environment," *In AIAA SPACE 2012 Conference & Exposition*, September 2012, pp. 5200-1~12.

21) Forrester, A., Sobester, A., and Keane, A., *Engineering Design via Surrogate Modelling: A Practical Guide*, John Wiley & Sons, Chichester, UK, 2008, pp. 49~63.