



MEiL

Strategie instrumentacji w oparciu o model zredukowany POD

Wojciech Gryglas

Opiekun: dr hab. inż. Jacek Szumbariski

7 kwietnia 2017

Politechnika Warszawska, Wydział MEiL, Zakład Aerodynamiki


- Liczba punktów pomiarowych jest zawsze ograniczona.
- Intuicja zawodzi w przypadku złożonych problemów.
- Ograniczenie błędu pomiarowego.
- Uzyskanie jak największej ilości informacji.

Rozważmy problem pomiaru wagi obiektów A, B, C, \dots , których dokładna waga jest określona jako m_A, m_B, m_C, \dots

Przyjmijmy następujące założenie:

1. Każdy pomiar jest obarczony losowym błędem.
2. Średnia błędów jest równa zero.
3. Odchylenie standardowe rozkładu prawdopodobieństwa błędu jest takie samo dla każdego pomiaru i jest równe σ
4. Błędy pomiędzy pomiarami są niezależne

Dokonyjemy pomiaru oddzielnie dla obiektu A oraz B



Oznaczmy wyniki pomiarów jako y_1 i y_2 oraz przyjmijmy, że $\sigma = 0.1$:

$$\begin{aligned} y_1 &= m_A \pm \sigma \\ y_2 &= m_B \pm \sigma \end{aligned} \Rightarrow \begin{aligned} m_A &= y_1 \pm \sigma \\ m_B &= y_2 \pm \sigma \end{aligned}$$

Wariancja błędu oszacowania m_A i m_B jest równa σ^2 .


Pomiar możemy zapisać w formie macierzowej:

$$\mathbf{y} = \mathbf{X}\beta + \varepsilon$$

gdzie:

$$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \end{bmatrix}, \mathbf{X} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}, \beta = \begin{bmatrix} m_A \\ m_B \end{bmatrix}, \varepsilon = \begin{bmatrix} \sigma \\ \sigma \end{bmatrix}$$

Rozważmy przypadek pomiaru dokonanego w nieznacznie inny sposób:



$$\begin{aligned}
 m_A + m_B \pm \sigma &= y_1 \\
 m_A - m_B \pm \sigma &= y_2
 \end{aligned}
 \Rightarrow
 \begin{aligned}
 m_A &= \frac{1}{2}(y_1 \pm \sigma) - \frac{1}{2}(y_2 \pm \sigma) \\
 m_B &= \frac{1}{2}(y_1 \pm \sigma) + \frac{1}{2}(y_2 \pm \sigma)
 \end{aligned}$$

$$\text{var}(m_A) = \text{var}(m_B) = \frac{1}{4}\sigma^2 + \frac{1}{4}\sigma^2 = \frac{1}{2}\sigma^2$$

$$m_A = y_1 - y_2 \pm \frac{\sigma}{\sqrt{2}} = y_1 - y_2 \pm 0.7\sigma \qquad m_B = y_1 + y_2 \pm 0.7\sigma$$

Ponownie, zapisując pomiar w formie macierzowej $\mathbf{y} = \mathbf{X}\beta + \varepsilon$ otrzymujemy

$$\mathbf{X} = \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix}$$

Okazuje się, że obniżenie wariancji estymowanych parametrów jest ściśle związane z macierzą $\mathbf{X}^T\mathbf{X}$:

$$\det \left(\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}^T \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \right) = 1 \quad \text{vs} \quad \det \left(\begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix}^T \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \right) = 4$$

Macierz $\mathbf{M} = \mathbf{X}^T\mathbf{X}$ nazywa się **Macierzą informacji Fishera**.

Jeśli obserwacje pochodzące z eksperymentu są modelowane jako:

$$\mathbf{Y} = \mathbf{X} \cdot \mathbf{a} + \varepsilon$$

$$E[\varepsilon] = 0 \quad \text{cov}(\varepsilon) = E[\varepsilon\varepsilon^T] = \sigma^2\mathbf{I}$$



to estymator parametrów modelu (w sensie najmniejszych kwadratów) będzie miał postać:

$$\hat{\mathbf{a}} = (\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T\mathbf{Y}$$

Estymator $\hat{\mathbf{a}}$ jest także zmienną losową, dla którego:

$$\text{cov}(\hat{\mathbf{a}}) = \sigma^2(\mathbf{X}^T\mathbf{X})^{-1}$$

która określa rozproszenie $\hat{\mathbf{a}}$ wokół poszukiwanej wielkości \mathbf{a}



$$M = X^T \cdot X$$

- *A-optimum*: najmniejsza średnia długość elipsoidy niepewności.

$$\Psi(M) = \text{tr}(M^{-1})$$

- *D-optimum*: najmniejsza objętość elipsoidy niepewności.

$$\Psi(M) = \log(\det(M^{-1}))$$

- *E-optimum*: minimalizacja większej osi elipsoidy niepewności.

$$\Psi(M) = \lambda_{\max}(M^{-1})$$

- Model liniowy opisujący przykładowe zjawisko można zapisać:

$$\mathbf{Y} = \mathbf{X} \cdot \mathbf{a} + \varepsilon$$


\mathbf{Y} - dane pomiarowe, \mathbf{a} - współczynniki modelu, \mathbf{X} - stałe związane z modelem, ε - błąd losowy.

- Najprostszy model $y = a_0 + a_1 \cdot x$:

$$\mathbf{X} = \begin{bmatrix} 1 & x_0 \\ \vdots & \vdots \\ 1 & x_N \end{bmatrix} \quad \mathbf{a} = \begin{bmatrix} a_0 \\ a_1 \end{bmatrix}$$

gdzie x_0, \dots, x_N odpowiadają lokalizacji punktów pomiarowych.

- Co najmniej 2 równania są potrzebne aby wyznaczyć \mathbf{a} . Wybór odpowiednich wierszy z macierzy \mathbf{X} pozwala kontrolować dokładność oszacowania \mathbf{a} .



A - optimum:

$$\Psi = \text{tr}(M^{-1}) = \frac{x_1^2 + x_2^2 + 2}{(x_1 - x_2)^2}$$

Najmniejszej wartości Ψ odpowiada para $x_1 = -1$ i $x_2 = 1$

Sprawdzenie

Wariancja estymatora parametru a_1 dla dwóch pomiarów ($N = 2$) można obliczyć jako:

$$\text{Var}(\hat{a}_1) = \frac{1}{\Delta x^2} [\text{Var}(y_2) + \text{Var}(y_1)] = \frac{2}{\Delta x^2} \sigma^2$$

Najmniejszej wartości wariancji estymatora a_1 odpowiadają pozycje $x_1 = -1$ and $x_2 = 1$.

1. Wykonaj N obliczeń numerycznych pokrywających dopuszczalną przestrzeń parametrów (np.: różne kąty natarcia, prędkości wlotowe).
2. Utwórz model zredukowany bazując na wykonanych obliczeniach.
3. Skorzystaj z modelu w celu obliczenia kryterium statystycznego.
4. Wybierz punkty pomiarowe, tak aby wartość kryterium statystycznego była najmniejsza.
5. Wykonaj eksperyment i zbierz dane ze wskazanych punktów pomiarowych.
6. Zrekonstruuuj pole przepływu wykorzystując model zredukowany i dane eksperymentalne.

Symulacja CFD → model liniowy → optymalizacja → eksperyment
+ model liniowy → rekonstrukcja.


Wymagania modelu liniowego:

- Jak najbardziej ogólny.
- Stabilny numerycznie.


Model zredukowany w oparciu o metodę Proper Orthogonal Decomposition:

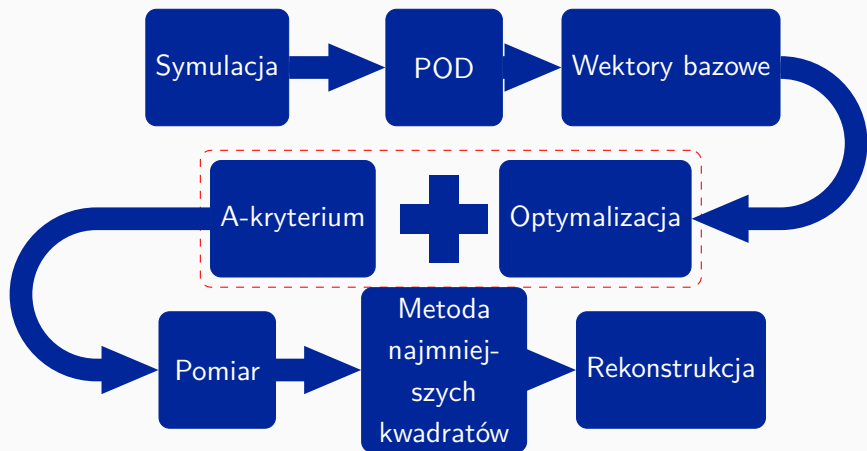
$$\mathbf{V} = [\mathbf{V}_1, \dots, \mathbf{V}_n] \approx \left[\sum_{i=0}^m \mathbf{M}_i \cdot \beta_{1i}, \dots, \sum_{i=0}^m \mathbf{M}_i \cdot \beta_{ni} \right]$$

\mathbf{M}_i - wektory bazowe uzyskane za pomocą POD.



vs





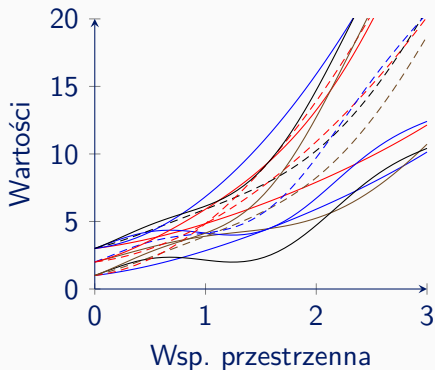
1. Wybierz p punktów z P dostępnych, rozłożonych możliwie najbardziej równomiernie.
2. Wybierz jeden punkt z p i oblicz A-kryterium dla wszystkich dostępnych położeń zdefiniowanych przez P .
3. Wskaż nową pozycję dla rozważanego punktu tak aby odpowiadająca mu wartość A-kryterium była najmniejsza.
4. Przejdź do następnego punktu ze zbioru p i powtórz obliczenia z punktów 2 i 3 do momentu aż minimalna wartość A-kryterium zostanie osiągnięta.

**Zastosowanie metody dla przykładowego,
jednowymiarowego problemu**

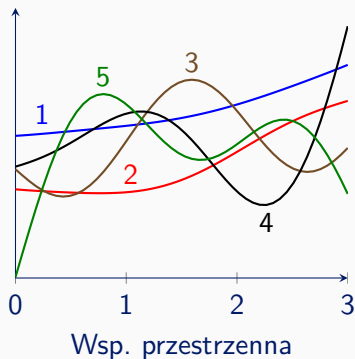
$$y = a \cdot x^2 + \sin(b \cdot x) + c$$

$$a, b, c = \{1, 2, 3\}$$

Realizacje



Wektory bazowe



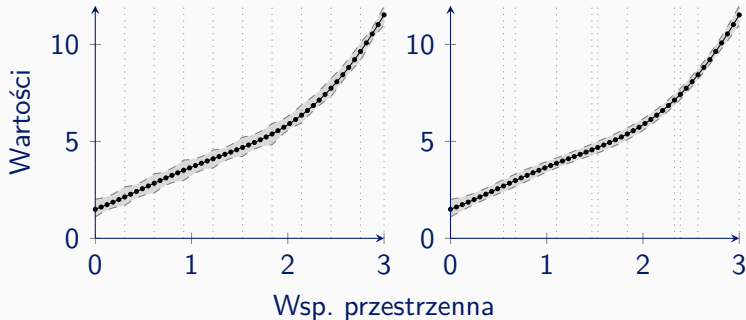
$a = 1.2$

$b = 1.8$

$c = 1.5$

Interpolacja liniowa

Rekonstrukcja



..... Punkty pomiarowe

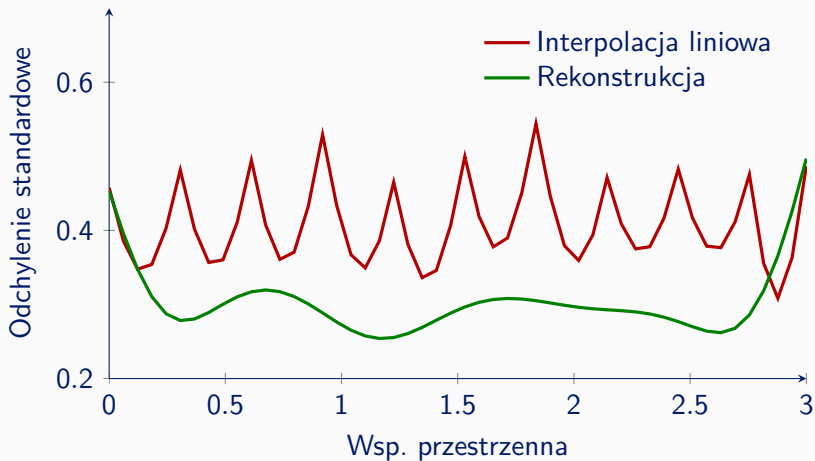
 σ

—•— Roz. dokładne

$$a = 1.2$$


$$b = 1.8$$

$$c = 1.5$$



**Walidacja metody w oparciu o dane
pochodzące ze sztucznego eksperymentu**

- Obliczenia numeryczne na siatce gęstej - imitacja danych eksperymentalnych poprzez dodanie losowego błędu.
- Obliczenia na siatce rzadkiej - dane do optymalizacji instrumentacji.
- Rekonstrukcja pola przepływu w oparciu o dane zebrane z obliczeń na siatce gęstej w wyznaczonych punktach.




Optymalizacja


vs

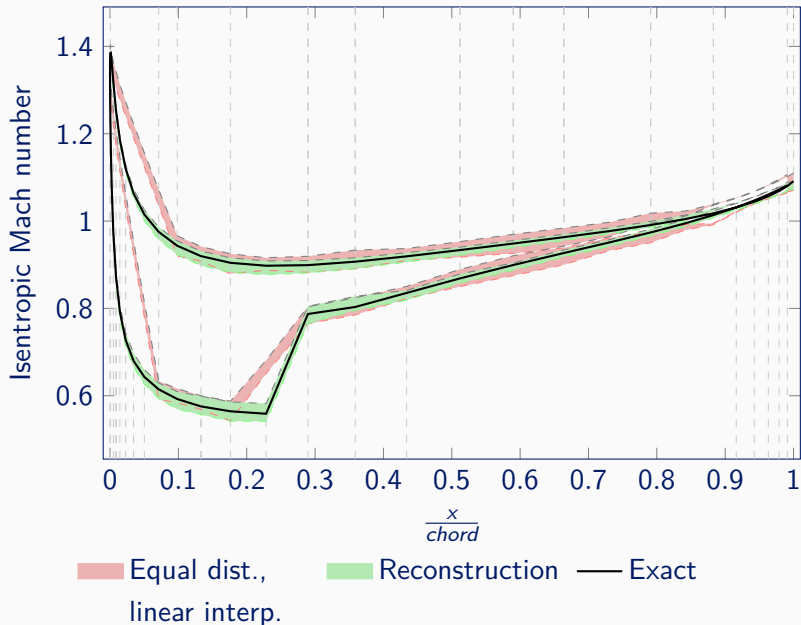
Wirtualny eksperyment

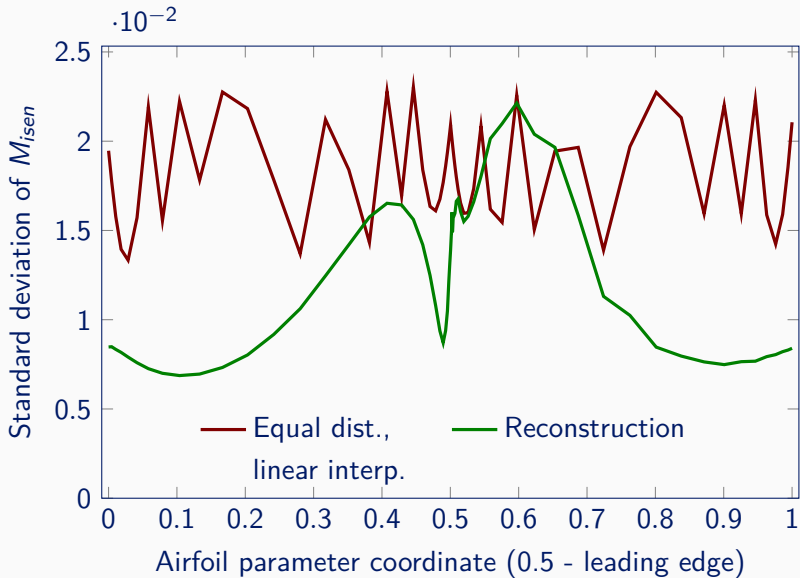
- Kąty natarcia: $1.2^\circ - 3.2^\circ$
- Zakres liczb Macha: 0.2 - 0.7





- profil
- optymalne położenia
- × równomierny, początkowy rozkład










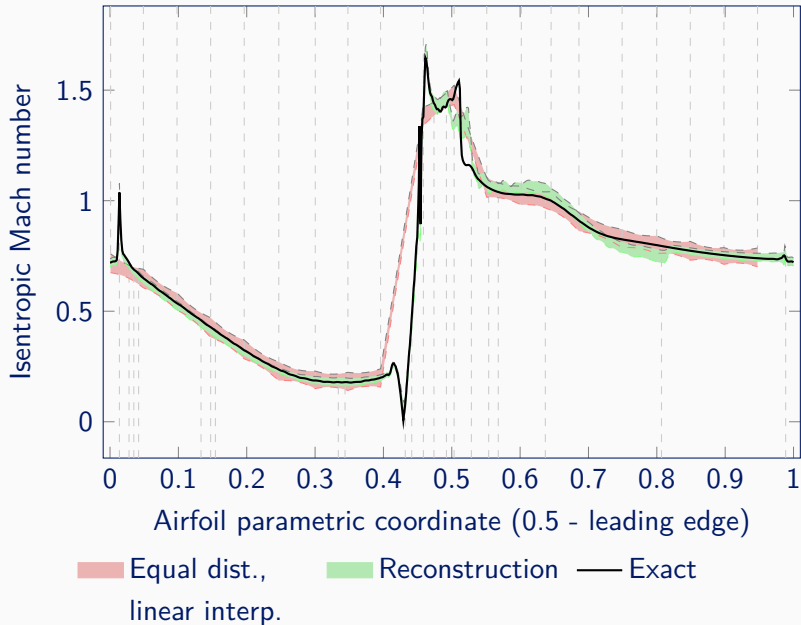
Optymalizacja vs


Wirtualny eksperyment

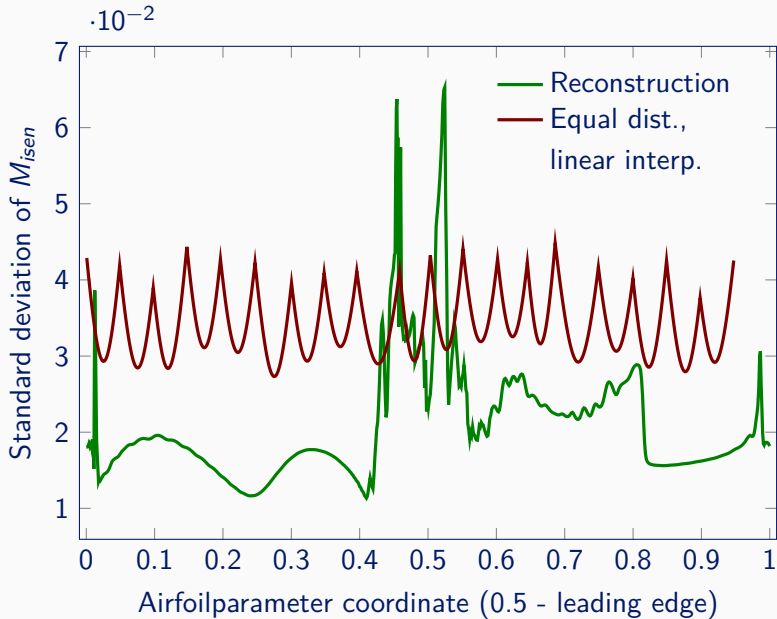
- Zakres kątów natarcia: $0^\circ - 25^\circ$
- Zakres liczb Macha: 0.38 - 0.9





- profil
- optymalne położenia
- × równomierny, początkowy rozkład













Założone pole przepływu




Pole pochodzące z rekonstrukcji

Walidacja metody w oparciu o dane eksperymentalne




Eksperyment - 69 punktów pomiaru ciśnienia




- Wybór 11 optymalnych punktów pomiarowych z dostępnych 69
- Model zredukowany POD (5 wektorów bazowych - 5 parametrów) w oparciu o dane obliczeniowe pochodzące z 200 konfiguracji
- Dane przygotowane dla zmiennego kąta natarcia i liczby macha na wlocie

Przypadek poddźwiękowy




- profil
- dostępne położenia
- optymalne położenia
- × równomierny, początkowy rozkład

Wylotowa liczba Macha 0.7257




- dane wykorzystane do rekonstrukcji
- rekonstrukcja profilu
- wszystkie dane eksperymentalne



Liczba Macha na wylocie 0.737


- Wypełnienie - rekonstrukcja
- Kontury - najbliższe rozwiązanie numeryczne z punktu widzenia warunków eksperymentu

Przypadek pod- i naddźwiękowy na raz




- profil
- dostępne położenia
- optymalne położenia
- × równomierny, początkowy rozkład

Wylotowa liczba Macha 0.8398



- dane wykorzystane do rekonstrukcji
- rekonstrukcja profilu
- wszystkie dane eksperymentalne

Wylotowa liczba Macha 1.1509



- dane wykorzystane do rekonstrukcji
- rekonstrukcja profilu
- wszystkie dane eksperymentalne

- Zaproponowana metoda pozwala na wybór punktów pomiarowych, tak aby wariancja błędu była zminimalizowana.
- Dzięki zastosowaniu modelu opartego na POD metoda jest ogólna i może być szeroko stosowana do wielu innych problemów.
- Przeprowadzone testy potwierdzają poprawne działanie metody.
- Model zredukowany POD pozwala dodatkowo odtworzyć całe pole przepływu.



Narodowe Centrum
Badań i Rozwoju

Poniższa praca została wykonana w ramach programu COOPERNIK finansowanego przez Narodowe Centrum Badań i Rozwoju.



Badania otrzymały wsparcie Wydziału MEiL za pośrednictwem "Grantu dziekańskiego".

Dziękuję za uwagę