

6.3.2 Dyskryminacja cech metodą ortogonalizacji składowych wektora obserwacji

Składowe wektora obserwacji $S_i(\Theta)$, $i=1, \dots, s$ są amplitudami wielkości fizycznych, np. przyspieszenia, prędkości, przemieszczenia drgań; składowymi widmowymi tych wielkości lub innymi symptomami i dyskryminantami procesów WA (patrz rozdział 6.3). W wyniku zastosowania procedury BEDIND z ich liniowej kompozycji powstają poszukiwane cechy (uszkodzenia) jako składowe główne macierzy obserwacji. Czy jednak niektóre cechy nie mogą być wprost wielkościami mierzalnymi w eksperymencie? Jest to istotne zwłaszcza w pomiarach normowych, gdzie jesteśmy zmuszeni posługiwać się określonymi wielkościami drganiowymi. Ponadto tradycje pomiarowe i predyspozycje prowadzących badania też są nieraz nie do odrzucenia. Doceniając ten problem próbowano w procedurze BEDIND wprowadzić symptomy „priorytetowe”, tzn. takie, które mimo wskazań procedury odrzucania zbędnych symptomów pomiarowych muszą pozostać do końca algorytmu. Matematycznie jest to równoważne narzuceniu każdorazowo dodatkowych więzów na układ, gdyż „priorytet” interweniuje w procedurze odrzucenia. Z pewnością jest to źródłem dużych błędów nie łatwych do oszacowania. Istnieją jednak procedury ortogonalizacji znanego układu wektorów (funkcji), w których punkt startowy może być wybrany dowolnie. Np. może to być amplituda przyspieszenia drgań zalecana normowo do pomiaru w obserwowanej grupie maszyn, zaś pozostałe cechy ortogonalne do cechy wyjściowej (tu przyspieszenia) dobiera się na podstawie specjalnego algorytmu Grama-Schmidta [115. rozdz. 3.3], [116 punkt 14.7.4.].

Niech realizacja pomiaru każdego symptomu „i” daje nam zawsze wektor $\{S_i\} = m\{S_{i1}, \dots, S_{in}\}^T$, $i=1, \dots, s$. Załóżmy dalej, że jako pierwszy $i=1$ ustawiliśmy symptom prowadzący, np. normowe przyspieszenie drgań. Wtedy poszukiwanie dalszych ortogonalnych składowych nowego wektora obserwacji $\{W_1\}$ przebiega:

$$\begin{aligned} \{W_i\} &= \{S_i\} \\ \{W_{i+1}\} &= \{S_{i+1}\} - \sum_{k=1}^i \frac{\{W_k\}^T \{S_{i+1}\}}{\{W_k\}^T \{W_k\}} \{W_k\} \quad i=1,2,\dots \end{aligned} \quad (6.13)$$

Cameron [115] zauważył, że proces takiej ortogonalizacji można znacznie przyspieszyć, jeśli wektory $\{W_i\}$ zerujące się na zadanym poziomie istotności przenosić na koniec zbioru wyjściowego $\{S_i\}$. W takim razie procedurę (6.13) prowadzi się do tego miejsca aż wszystkie wektory pozostałe do transformacji okażą się zerowymi.

Wracając do relacji definiującej nowej składowe wektora obserwacji, dla centrowanych wektorów $\{S_i\}$ tzn. $\sum_i E_j \{S_i\} = 0$, pierwszy czynnik sumy jest niczym innym jak współczynnikiem korelacji między k-tą składową nowo utworzonego wektora a obrabiane na kolejnym „i+1” - pierwszym kroku składową pierwotnego wektora obserwacji $\{S_{i+1}\}$. Jeśli więc obrabiany właśnie wektor $\{S_{i+1}\}$ będzie ortogonalny do obliczonych już składowych nowego wektora, tzn. będzie $\{W_k\}^T \{S_{i+1}\} = 0$, $k=1, \dots, i$, to $\{W_{i+1}\} = \{S_{i+1}\}$ i na tym kroku algorytm ortogonalizacji się kończy.

Jak dotychczas nie ma prób wykorzystania tego prostego algorytmu do dyskryminacji cech układu zmiennych losowych powstałych w wyniku obserwacji grupy obiektów zorientowanej na określoną wielkość pomiarowe. Są jedynie próby wykorzystania algorytmu ortogonalizacji do obróbki procesów losowych [117], o czym będziemy mówić w punkcie 6.5.

