

4.2.2. Model niejawny typu obrazu

Powiązanie przyczynowo-skutkowe między symptomem WA a cechą stanu X lub czasem eksploatacji Q, mimo że zawsze istnieje i jest podstawą diagnostyki, nie zawsze jest znane w sensie analitycznym. W diagnostyce obiektów z wielowymiarową przestrzenią uszkodzeń nie zawsze znane jest przyporządkowanie; symptom \rightarrow uszkodzenie lub symptom \rightarrow stan, symptom \rightarrow czas życia. W takich przypadkach wiadomo np., że dla danego stanu wektor symptomów WA $\{s\} = \text{col} \{s_1, \dots, s_n\}$ winien mieć składowe o określonej wartości lub zbliżone, lecz nie jest jasne dlaczego takie (nieznane przyporządkowanie względem cech stanu X) i kiedy to nastąpi (nieznane przyporządkowanie względem czasu życia θ). Mówiąc obrazowo, wiemy jedynie jak powinien „wyglądać” $\{S\}$ obiektu w stanie zdatnym lub/i niezdatnym.

Każdy obiekt mechaniczny opisany jest w naszym przypadku wektorem $[S]$ w n-wymiarowej przestrzeni symptomów WA i możemy mówić, że zbiór współrzędnych tego obiektu S_1, \dots, S_n tworzy punkt lub obraz w tej n — wymiarowej przestrzeni. Rozpoznanie stanu X, jaki reprezentuje ten obiekt, może więc być traktowane jako rozpoznanie WA obrazu stanu dane przez (S), jeśli wiemy jak to robić. Nauczenie się rozpoznawania jest możliwe, jeśli mamy wektory symptomów $\{S\}_p$ dla grupy obiektów $p = 1, \dots, k$ o znanym stanie zdatności. Mówimy wtedy o znanych zbiorach trenujących

$$\begin{aligned} (s)_p = \{s^z\} &\rightarrow \text{STAN ZDATNY}, \quad p = 1 \dots k, \\ \{s\}_p = \{S^n\} &\rightarrow \text{STAN NIEZDATNY}, \quad p = k+1, \dots, r \end{aligned} \tag{4.8}$$


gdzie $\{s^z\}$ oznacza obszar stanu zdatności. $\{S^n\}$ obszar stanu niezdatności w n-wymiarowej przestrzeni symptomów WA.

Rozpoznanie stanu zdatności innego obiektu z obrazem $\{s\}$. będzie teraz przebiegało wg relacji przynależności do znanych zbiorów trenujących

$$\begin{aligned} \{s\}_i \in \{S^z\} &\rightarrow \text{ZDATNY} \\ \text{lub} \\ \{s\}_i \in \{S^n\} &\rightarrow \text{NIEZDATNY}. \end{aligned} \tag{4.9}$$

Obecnie w zależności od sposobu określenia relacji przynależności do zbiorów trenujących będziemy mieli różne metody rozpoznawania obrazów (patrz np. [82] a w zastosowaniu do diagnostyki monografię Birgera[13])

i pracę habilitacyjną Cholewy [83]). Generalnie metody rozpoznawania można podzielić na dwie grupy. Metody odległościowe, które funkcję przynależności budują na różnych miarach odległości (Euklidesa, Haminga itd) rozpoznawanego obrazu od zbiorów trenujących. Druga grupa metod polega na podziale przestrzeni symptomów na podprzestrzeń stanu zdatnego i niezdatnego za pomocą hiperpowierzchni decyzyjnej $\Phi(\{s\})=0$, a ma to szczególne zastosowanie przy dwuklasowym podziale stanu. Ponieważ równanie takiej powierzchni nie zawsze da się łatwo znaleźć, stąd też mamy tutaj całą gamę metod bezpośredniego wyznaczania tej powierzchni. Sam efekt działania hiperpowierzchni najłatwiej zilustrować rozpoznawaniem przypadków z symptomem jednowymiarowym i dwuwymiarowym tak, jak na rysunku 4.2a i b.



Rys.4.2. Rozpoznawanie WA obrazu stanu obiektu w przypadku jednowymiarowym (a) i dwuwymiarowym (b);

Analiza obu rysunków wykazuje duże analogie do wnioskowania w modelach regresyjnych. Wyznaczenie linii decyzji w przypadku jednowymiarowym jest równoznaczne z wyznaczeniem wartości granicznej dla symptomu S_1 , równej S_{1i} . Analogia przypadku dwuwymiarowego jest bardziej subtelna, niemniej jednak też oczywista.

Z przedstawionych ilustracji wynika, że przy zadanej hiperpowierzchni decyzyjnej reguła klasyfikacji (rozpoznawania) stanu winna być następująca:

$$\begin{aligned} \text{sgn}\Phi(\{s\}_1) &= \{+1, \{s\}_1 \in \{s^n\} \rightarrow \text{NIEZDATNY}\} \\ \text{sgn}\Phi(\{s\}_1) &= \{-1, \{s\}_1 \in \{s^z\} \rightarrow \text{ZDATNY}\} \end{aligned}$$

(4.10)

gdzie funkcja znaku: $\text{sgn}(\alpha) = +1$ dla $\alpha \geq 0$ oraz $\text{sgn} \alpha = -1$ dla $\alpha < 0$.

Mając już wyjaśnione ideę rozpoznawania stanu w wielowymiarowej przestrzeni symptomów WA przystąpmy do wyznaczania hiperpłaszczyzny $\Phi(\{s\})=0$. [W wielu przypadkach diagnostyki i dwustanowej oceny stanu hiperpowie-rzchnia rozdzielająca może mieć postać hiperpłaszczyzny pojedynczej lub łamanej. W tym pierwszym przypadku funkcja decyzyjna będąca równaniem hiperpłaszczyzny ma postać:

$$\Phi(\{s\}) = \{\lambda\}\{s\} = \sum_{j=1}^n \lambda_j s_j = 0, \quad (4.11)$$

gdzie $\{\lambda\}$ jest nieznanym wierszowym wektorem wag takim, że iloczyn skalarny obu wektorów jest zerowy.

Ostatnia relacja i reguła decyzyjna (4.10) przedstawiają sposób działania tzw. klasyfikatora liniowego i cały jego problem sprowadza się do obliczenia składowych λ_j wektora wag $\{\lambda\}$ na podstawie WA obrazów obiektów o znanych stanach. Procedura znajdowania wektora $\{\lambda\}$ nosi również nazwę procedury uczenia się i wg Birgera [13] oraz Tou [82] może być wykonana jako ciąg iteracji na znanych obrazach $\{s\}_p$. Biorąc pierwszy obraz $\{s\}_1$ możemy napisać pierwsze przybliżenie wektora $\{\lambda\}$ w postaci:

$$\{\lambda\}_1 = \{s\}_1, \text{ jeśli } \{s\}_1 \in \{s^n\} \text{ STAN NIEZDATNY}$$

lub też

$$\{\lambda\}_1 = \{s\}_1, \text{ jeśli } \{s\}_1 \in \{s^z\} \text{ STAN ZDATNY} \quad (4.12)$$

Płaszczyzna decyzyjna dla tego przybliżenia jest określona równaniem:

$$\Phi_1(\{s\}) = \{\lambda\}_1 \{s\} = 0,$$

zaś ogólnie dla n-tego przybliżenia

$$\Phi_n(\{s\}) = \{\lambda\}_n \{s\},$$

$$\{\lambda\}_n = \{\lambda\}_{n-1} + \frac{1}{2} [\text{sgn } \Phi(\{s\}_n) - \text{sgn } \Phi_{n-1}(\{s\}_n)] \{s\}_n.$$

(4.13)

gdzie $\{s\}_n$ kolejny obraz trenujący o znanym stanie i znanym znaku funkcji decyzyjnej $\Phi > (\{s\}_n)$, oraz $\Phi_{n-1}(\{s\}_n)$ to wartość n-1-szego przybliżenia tej funkcji dla obrazu $\{s\}_n$.

Można wykazać, że ciąg takich iteracji prowadzi w granicy do obliczenia wektora $\{\lambda\}$, a tym samym do znalezienia liniowej postaci funkcji decyzyjnej $\Phi\{s\}$. W obliczeniach praktycznych dogodnie jest rozszerzyć wymiar wektora $\{s\}$ dodając jedynekę jako pierwsze składowe. Wtedy wektor $\{\lambda\}$ może również ujmować przypadki hiperpłaszczyzn nie przechodzących przez środek układu współrzędnych. Z innych metod rozpoznawania o prostej strukturze logicznej warto tu wymienić w ślad za Batchelorem [84]: metodę najbliższego sąsiada oraz metodę hiperstref. W pierwszym przypadku funkcja decyzyjna jest łamaną hiperpłaszczyzną, zaś w drugim jest złożona z segmentów hipersfer. Aparaturowa realizacja obu metod jak i klasyfikatora liniowego jest bardzo prosta i wykonalna za pomocą diod i rezystorów, a jeszcze prościej przebiega to wg standardowych programów minikomputerowych.

Dla prawidłowego określenia kształtu funkcji decyzyjnej wg tych metod potrzebny jest trenujący zbiór o rozmiarze kilkudziesięciu obiektów. Po zakończeniu procesu uczenia można już przystąpić do automatycznego rozpoznawania stanu maszyny na podstawie zmierzonego zbioru symptomów WA , (S) , będących WA obrazem stanu obiektu.

Wyżej przedstawiliśmy jedynie najprostszą wersję diagnostycznego modelu niejawnego - typu obrazu, ograniczając się do liniowych i zdeterminowanych, metod wnioskowania. - Rozpoznawanie obrazów jest prężnie rozwijającą się dyscypliną i wiele jeszcze można zaadaptować tu do celów diagnostyki (patrz rozdz.6).