

6.4. ROZPOZNAWANIE STANU

W rozdziale 4 omówiliśmy najważniejsze modele diagnostyczne obiektów mechanicznych dające przyporządkowanie „symptom \rightarrow stan”. W modelu niejawnym typu obrazu omówiliśmy geometryczne metodę rozpoznawania stanu przez konstrukcji hiperpowierzchni decyzyjnej. Oprócz tej metody rozpoznawania istnieją jeszcze: metody minimalno - odległościowe, metody probabilistyczne i lingwistyczne [82]. Wydaje się więc, że warto tu pokrótce zarysować podstawy metod minimalno - odległościowych, które mogą znaleźć zastosowanie w diagnostyce maszyn (patrz np. [83]).

Wyobraźmy sobie, że mamy dwa zbiory wektorów symptomów tworzące macierze:

- zbiór trenujący - uczący ze znanym przyporządkowaniem stanu k-objektów,

$$\{S_{ir}^u\} \quad r = 1, \dots, k, \quad u = \begin{cases} z - \text{zdatny} \\ n - \text{niezdatny} \end{cases}$$

- zbiór n-objektów - do rozpoznania ich stanu:

$$\{S_{ij}\} \quad j = 1, \dots, n, \tag{6.14}$$

gdzie $i=1, \dots, s$ to składowe wektora obserwacji każdego obiektu, ze zbioru trenującego $r=1, \dots, k$ oraz dla rozpoznawanego zbioru $j=1, \dots, n$.

Chcąc obecnie rozpoznać stan j-jtego obiektu obliczamy jego odległość d_{rj} od każdego obiektu zbioru uczącego. Na podstawie znajomości tych odległości możemy sądzić o podobieństwie rozpoznawanego obiektu do swego najbliższego sąsiada ($Min d_{jr}$) lub do innego wzorca stanu.

Istnieje wiele definicji odległości (dobry przegląd zagadnienia można znaleźć w pracy habilitacyjnej Cholewy [833]), zaś jedna z najogólniejszych, odległość Minkowskiego, została już tu wykorzystana przy definicji miar sygnału WA (patrz p. 3. 5) i do naszych celów można ją zapisać następująco:

$$d_{rj}^\mu = \left[\sum_{i=1}^s |S_{ij} - S_{ir}^u|^\mu \right]^{\frac{1}{\mu}}, \quad u = z : n \tag{6.15}$$

przy czym z uwagi na różnoimienność symptomów S_i i różne skale dobrze jest znormalizować cechy dzieląc je przez odchylenie standardowe na rozpatrywanym zbiorze

$$\sigma_i = \sqrt{\frac{1}{n} \sum_{j=1}^n (S_{ij} - \bar{S}_i)^2}, \quad \sigma_i^u = \sqrt{\frac{1}{k} \sum_{r=1}^k (S_{ir}^u - \bar{S}_i^u)^2} \tag{6.16}$$

gdzie \bar{S}_i, \bar{S}_i^u to wartości średnie symptomów

$$\bar{S}_i = \frac{1}{n} \sum_{j=1}^n S_{ij}, \quad \bar{S}_i^u = \frac{1}{n} \sum_{r=1}^k S_{ir}^u$$

Wybór wykładnika μ podyktowany jest naszymi potrzebami; jeśli chcemy uwzględnić jednako wszystkie cechy, to $\mu = 1$, jeśli zaś chcemy uwzględnić bardziej większe różnice w cechach, to należy przyjąć $\mu > 1$, zaś dla $\mu \rightarrow \infty$ otrzymujemy $d_{rj}^u = Max_i |S_{ij} - S_{ir}^u|$

Odległość d_{rj} jest miarą bliskości obiektów i miara ta może już być podstawą rozpoznania stanu. Zakładając np, że j-ty obiekt ma taki stan jak jego najbliższy sąsiad możemy przyjąć następującą regułę decyzyjną $D(S_j)$:

$$D(S_j) = \begin{cases} z, \text{ je\u015b\u015b} & \text{Min}_r d_{rj}^z < \text{Min}_r d_{rj}^n \\ n, \text{ je\u015b\u015b} & \text{Min}_r d_{rj}^n < \text{Min}_r d_{rj}^z \end{cases} \quad (6.17)$$

to znaczy przyjmujemy decyzje o zdatno\u015bci j-tego obiektu, je\u015bli jego najbli\u017csi s\u0105siad jest zdatny i odwrotnie.

Jak wida\u0107, regu\u0142a decyzyjna jest prosta, lecz ka\u017cdorazowo wymaga obliczenia odleg\u0142o\u015bci od wszystkich obiekt\u00f3w zbioru trenuj\u0105cego $S_{ir}^u, r = 1, \dots, k$. Istnieje wiele alternatyw zmierzaj\u0105cych do zmniejszenia ilo\u015bci oblicze\u0144 przy zachowaniu b\u0105d\u017c nawet poprawno\u015bci poprzedniej jako\u015bci klasyfikacji.

Poprzestaj\u0105c jednak na zaprezentowaniu ogólnej idei klasyfikacji minimalno - odleg\u0142o\u015bciowych i metody najbli\u017cszego s\u0105siada nie b\u0119dziemy si\u0119 dalej w to wg\u0142\u0119bia\u0107, tym bardziej w metody probabilistyczne lub lingwistyczne. Zainteresowanych odsy\u0142amy do literatury [82,83,84], a tak\u017ce[119].

Na zako\u0144czenie warto wspomnie\u0107 o udanej próbie klasyfikacji silnik\u00f3w spalinowych wprost za pomoc\u0105 sko\u0144czonych realizacji sygna\u0142\u00f3w z przetwornik\u00f3w zamontowanych na silniku pokazanej przez Gerscha, Brothertona i Brauna [55]. Tutaj u\u017cyto metody najbli\u017cszego s\u0105siada, a jako miary u\u017cyto diwergencji Kulbacka, patrz wz\u00f3r (3.18), która ma t\u0119 zalet\u0119, \u017ce pozwala wylicza\u0107 od razu prawdopodobie\u0144stwo b\u0142\u0119dnej klasyfikacji.