

Sztuczny nos elektroniczny i jego zastosowania w praktyce

Plan wykładu

1. Wprowadzenie
2. Układ sztucznego nosa
3. Czujniki pomiarowe
4. Inteligentne układy przetwarzania danych pomiarowych
5. Przykładowe zastosowania
6. Kierunki dalszych badań
7. Podsumowanie.

Wprowadzenie


„Sztuczny nos” to instrument pomiarowy wyposażony w dwa systemy:

- System pobierania i detekcji gazów i par
- System (algorytm) rozpoznawania widm zapachowych

Historia:

- 1953 - Zmiana potencjału powierzchniowego w wyniku absorpcji gazu zapachowego (Tanyolac, 1953)
- 1970 - Taguchi opatentował czujnik SnO₂
- Model nosa elektronicznego zbudowano z 3 czujników i prostego układu przetwarzania sygnałów w 1982 roku
- Lata 90-te: pierwsze komercyjne sztuczne nosy elektroniczne

Przykłady komercyjne




a) Model 4440B
(firmy Agilent technologies)

b) Model Prometheus
(firmy Alpha Mos)

c) Model A320 (firmy
Cyrano Sciences)


Układ „sztucznego nosa”



1. Filtr powietrza
2. Pompa zasysająca
3. Komora pomiarowa z matrycą sensorową
4. Interfejs pomiarowy wraz z zasilaczem
5. Komputer klasy PC


Stosowane czujniki

Czujniki tlenków metali: zmiana rezystancji elementu przy reakcji chemicznej między gazem zapachowym a tlenkiem metalu.



Stosowane czujniki

Polimerowe: zmiana stałej dielektrycznej (lub potencjału) elementu przy absorpcji gazu zapachowego przez łańcuch polimeru.




Stosowane czujniki


Masowe: wpływ przyjętych molekuł (zmiana masy) na wykrywalną zmianę częstotliwości drgań .



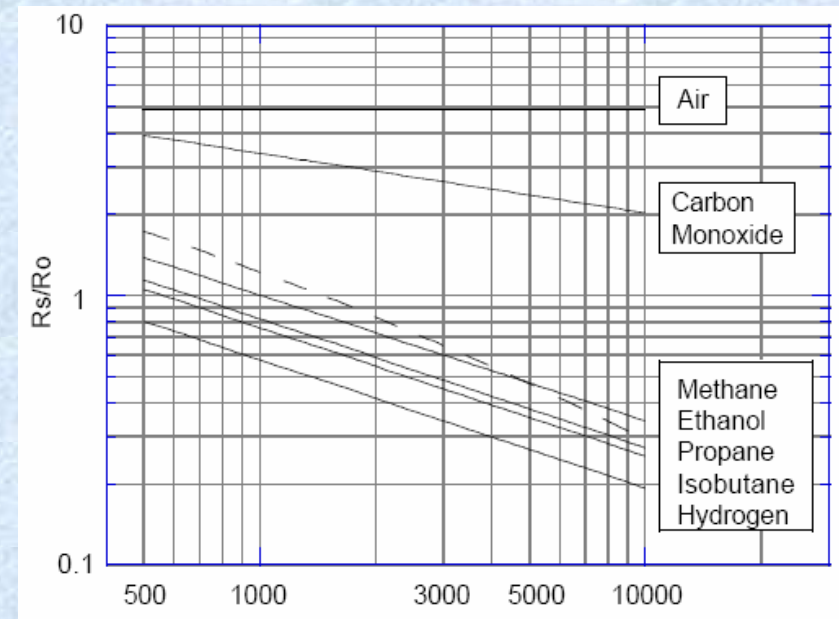
Charakterystyki czujnika typu tlenku metali



Charakterystyki czujnika typu tlenku metali



Zależność od temperatury i wilgotności przy 1000ppm metanu



Zależność R_s/R_o przy obecności różnych gazów i o różnych koncentracjach

Wynik pomiaru czujnikiem

Wynikiem pomiaru jest wartość aktualna rezystancji j-tego sensora $R(j)$. Do dalszego przetwarzania bierze się pod uwagę różnicę między aktualnym wynikiem a wartością referencyjną (baseline)

$$r(j) = \frac{R(j) - R_0(j)}{R_0(j)}$$

Wartość referencyjna $R_0(j)$ pochodzi z pomiaru wykonanego dla powietrza lub odniesiona do określonych (innych) warunków pomiarowych.

Porównanie czujników

	Selektywność	Czułość
Tlenków metali	●	●●●
Polimer półprzewodnikowy	●●	●●
Masowe	●●●	●

Charakterystyki czujników

- Zalety czujników o szerokim paśmie zapachowym:
 - Możliwość wykorzystywania czujnika do różnych zadań.
 - Niższy koszt.
- Wady:
 - Z powodu interferencji brak możliwości bezpośredniego wyznaczania wyników z odczytu czujnika.
 - Konieczność zastosowania większej liczby czujników (matrycy czujników) oraz dodatkowego układu przetwarzania sygnałów.

Inteligentne układy rozpoznawania i klasyfikacji - kalibracja

1. Cel zastosowania kalibracji

- Eliminacja szumu
- Eliminacja efektu interferencji widm czujników
- Skojarzenie wskazań czujników z obecnością i koncentracją określonego gazu

2. Najczęstsze techniki przetwarzania sygnałów:

- Technika PCA,
- Algorytm najbliższego sąsiada,
- Sieci neuronowe: MLP, SOM, TSK, SVM

Algorytm PCA

Algorytm PCA jest algorytmem pomocniczym i służy do rzutowania wektorów $\mathbf{x}^i \in \mathbf{R}^p$ do zbioru $\mathbf{y}^i \in \mathbf{R}^m$, gdzie $m < p$


$$\mathbf{x}^i \in \mathbf{R}^p \rightarrow \mathbf{W} \in \mathbf{R}^{m \times p} : \mathbf{y}^i = \mathbf{W}\mathbf{x}^i \in \mathbf{R}^m$$

$\mathbf{R}_{xx} = \mathbf{x} \cdot \mathbf{x}^T$ - macierz korelacji

$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$ - wartości własne macierzy \mathbf{R}_{xx}

$\mathbf{W} = [\mathbf{w}_1 \mathbf{w}_2 \dots \mathbf{w}_m]^T$ \mathbf{w}_i – wektor własny odpowiadający wartości własnej λ_i

Algorytm PCA



Dwa zbiory punktów w przestrzeni 3-wymiarowej leżących blisko płaszczyźnie $x+y+z=1$

Wyniki obliczenia algorytmu PCA

Wartości własne: [0.3085 0.1093 0.0063]

Wybieramy 2 składniki PC

Informacja =

$(0.3085+0.1093)/(0.3085+0.1093+0.0063)=98.52\%$

Odpowiadające wektory własne:

$\mathbf{w}_1 = [-0.4291 \quad -0.3818 \quad 0.8186]'$


$\mathbf{w}_2 = [0.7107 \quad -0.7021 \quad 0.0451]'$

$\mathbf{W} = [\mathbf{w}_1 \quad \mathbf{w}_2]'$

$\mathbf{y} = \mathbf{W}\mathbf{x}$

Wyniki obliczenia algorytmu PCA

$$y=Wx$$




Algorytm najbliższego sąsiada

- Zbiór wejściowy p wzorców \mathbf{x}^i należących do różnych klas
- Ze zbioru wejściowego generuje się prototypy klas.
- Liczba prototypów C jest mniejsza niż liczba wzorców.
- Przy podaniu nowej próbki, zalicza się tę próbkę do klasy, do której należy prototyp o najmniejszej odległości do niej.

Prototypy mogą być wyznaczone za pomocą algorytmów samoorganizacji, np. algorytmu C-mean, GK, itp.

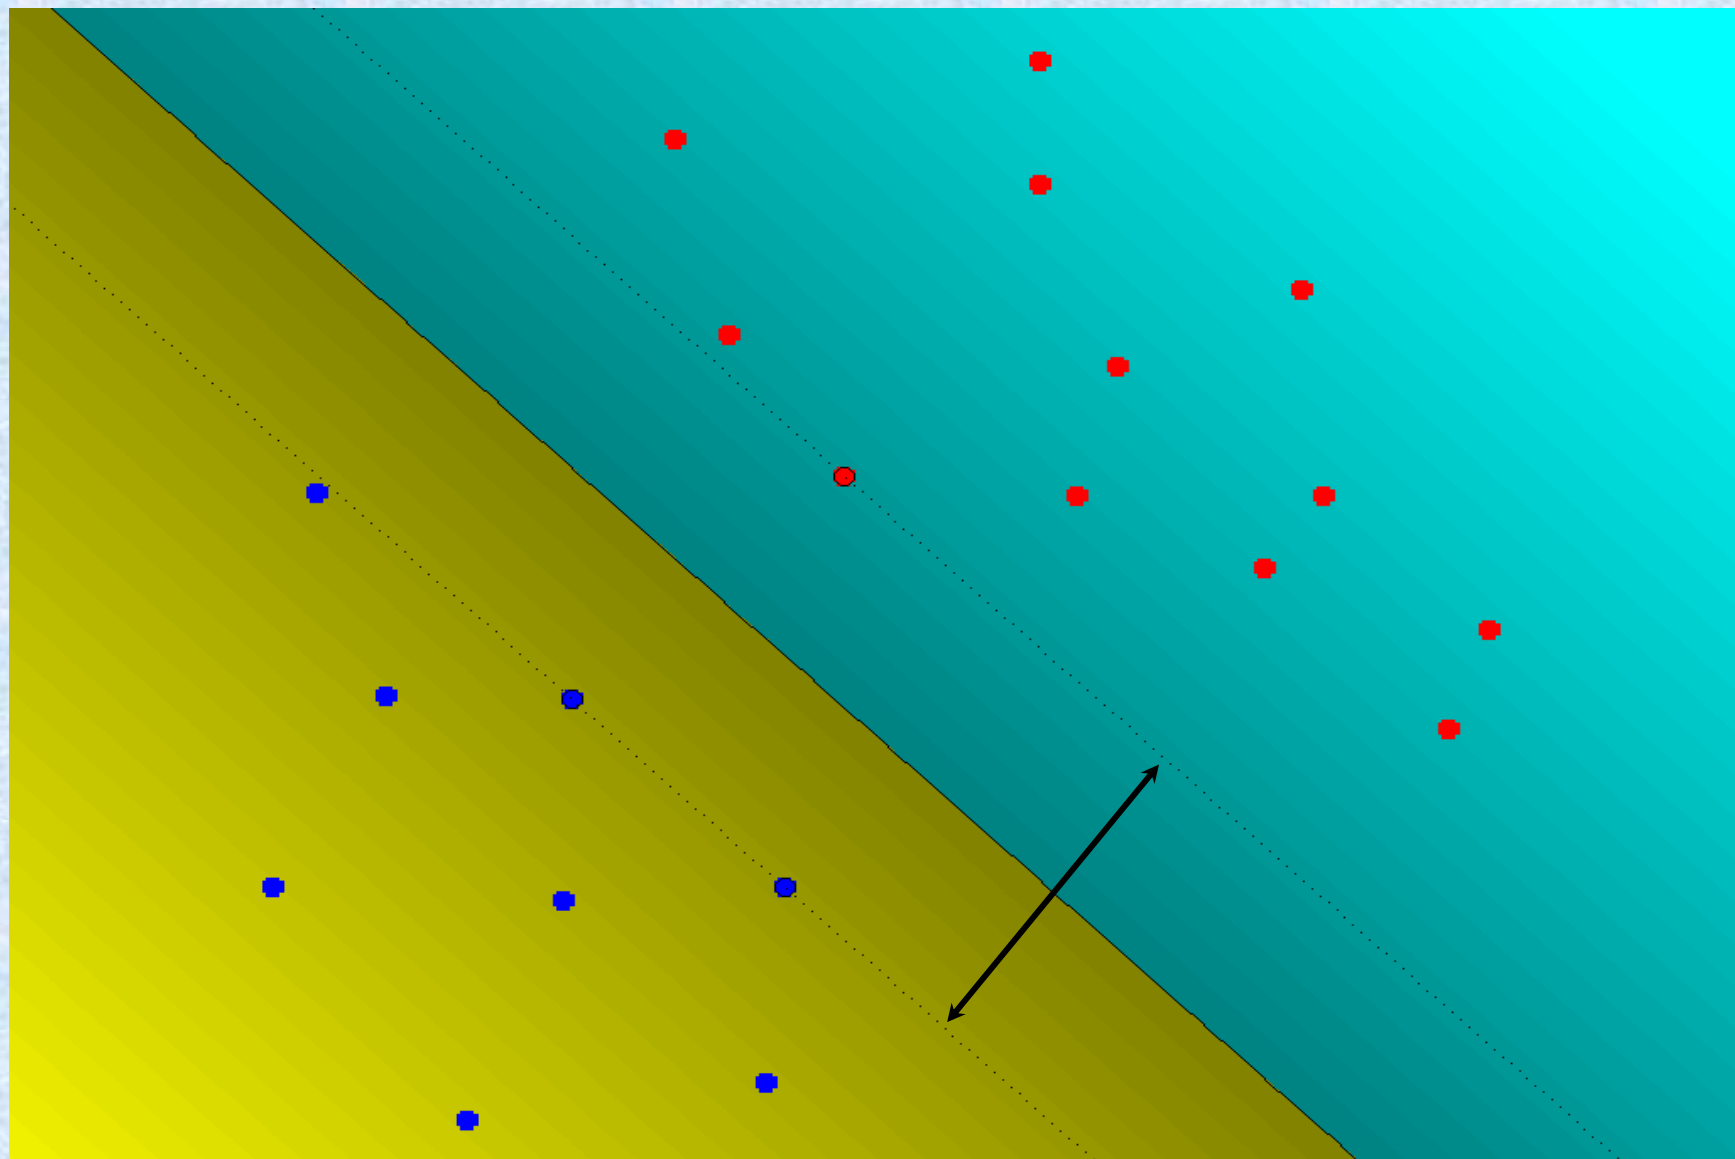
Algorytm najbliższego sąsiada




Sieć neuronowa SVM

- Klasyfikator 2-klasowy
- Klasyfikator 1-klasowy
- Układ aproksymujący


Sieć liniowa SVM




Sieć nieliniowa do separacji dwu klas



Zasada działania sieci jednoklasowej SVM





Przykładowe zastosowania

- Przemysł spożywczy (największy rynek):
 - Sprawdzanie jakości produktów spożywczych
 - Kontrola jakości procesów produkcji
 - Monitorowanie procesów fermentacji
 - Kontrola jakości (szczelności) pakowania
 - Rozpoznawania produktów: koniaku, wina, piwa,...
- Medycyna:
 - Wykrywanie i rozpoznawanie bakterii oczu
 - Wykrywanie raka płuc na podstawie wydychanego powietrza,
 - Wykrywanie obecność krwi w moczu
 - Wykrywanie bakterii we krwi,...

Przykładowe zastosowania

- Przemysł zbrojeniowy:
 - Wykrywanie min
 - Badanie jakości powietrza wewnątrz pojazdów (kosmicznych)
- Przemysł ochrony środowiska:
 - Badanie zanieczyszczeń powietrza
 - Wykrywania gazów trujących
 - Detekcja przecieku ropy,
 - Analiza składników paliwa,
 - Testowania jakości wody gruntowej,

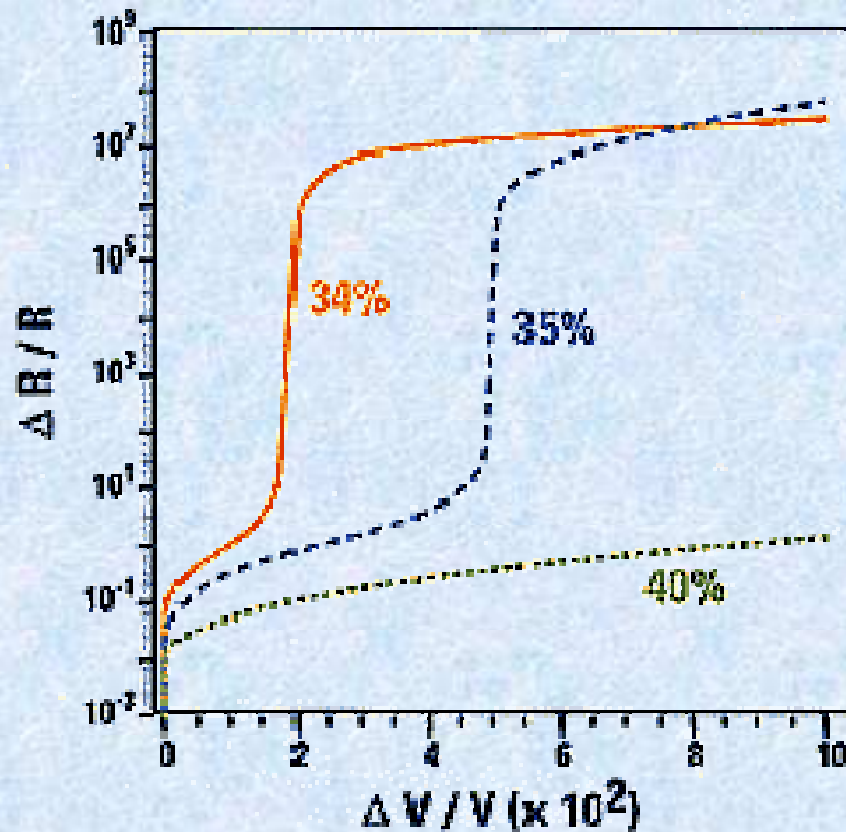
Wykrywanie bakterii oczu za pomocą komercyjnego nosa elektronicznego Cyranose A320

- 32 czujniki polimerowe o różnych spektrach gazowych
- Tryb pracy: uczenie (nagrywanie), testowanie (rozpoznawanie).
- Połączenie z komputerem poprzez łącze RS-232 lub USB
-



Komercyjny nos elektroniczny Cyranose A320

-Charakterystyka pracy czujnika w Cyranose A320 przy różnych grubościach warstwy polimeru



Specyfikacje Cyranose A320

- Czas próbkowania i przetwarzania sygnałów: 30 sekund
- Czas „oczyszczenia” układu pomiarowego: ok. 1 minuty
- Dane pomiarowe: względne zmiany rezystancji czujników po wchłonięciu gazu zapachowego.
- Algorytmy przetwarzania danych:
 - Filtrowanie wyższych częstotliwości
 - Unormowanie sygnałów dla czujnika i :

$$\Delta R_i = (R_i - R_{i0}) / R_{i0}$$

- Unormowanie sygnałów wszystkich czujników:

$$\Delta R_i = \Delta R_i / \left(\sum_{j=1}^{32} \Delta R_j \right)$$



Specyfikacje Cyranose 320

Algorytm rozpoznawania i klasyfikacji:

- Onboard:
 - Nearest Neighbour (NN)
 - Fisher linear discrimination (FLD)
 - Canonical discriminant analysis (CDA)
- PCA (outlier)



Wykrywania bakterii oczu

-6 rodzajów bakterii: SAR, HAI, STP, ECO, PSA i MOC

- Dane uczące:

- Każda bakteria: 3 roztwory o różnych koncentracjach NaCl.


- Każdy roztwór był „wąchany” 10 razy przez Cyranose.

- Liczba próbek: $6 \cdot 3 \cdot 10 = 180$.

- Do uczenia: 72 próbki losowo wybranych po 4 dla każdej bakterii.

- Do testowania: 96 próbek losowo wybranych po 6 dla każdej bakterii.

Wykrywania bakterii oczu



- **Liniowa PCA: 74%**

- **Sieć RBF : 98%**

Rozpoznawania i klasyfikacja mleka

- Problem: Rozpoznawanie i klasyfikacja pasteryzowanego mleka na podstawie jego zapachu
- Przez pasteryzację pojawiają lub znikają różne składniki zapachowe mleka tworząc różne profile zapachowe danego produktu.

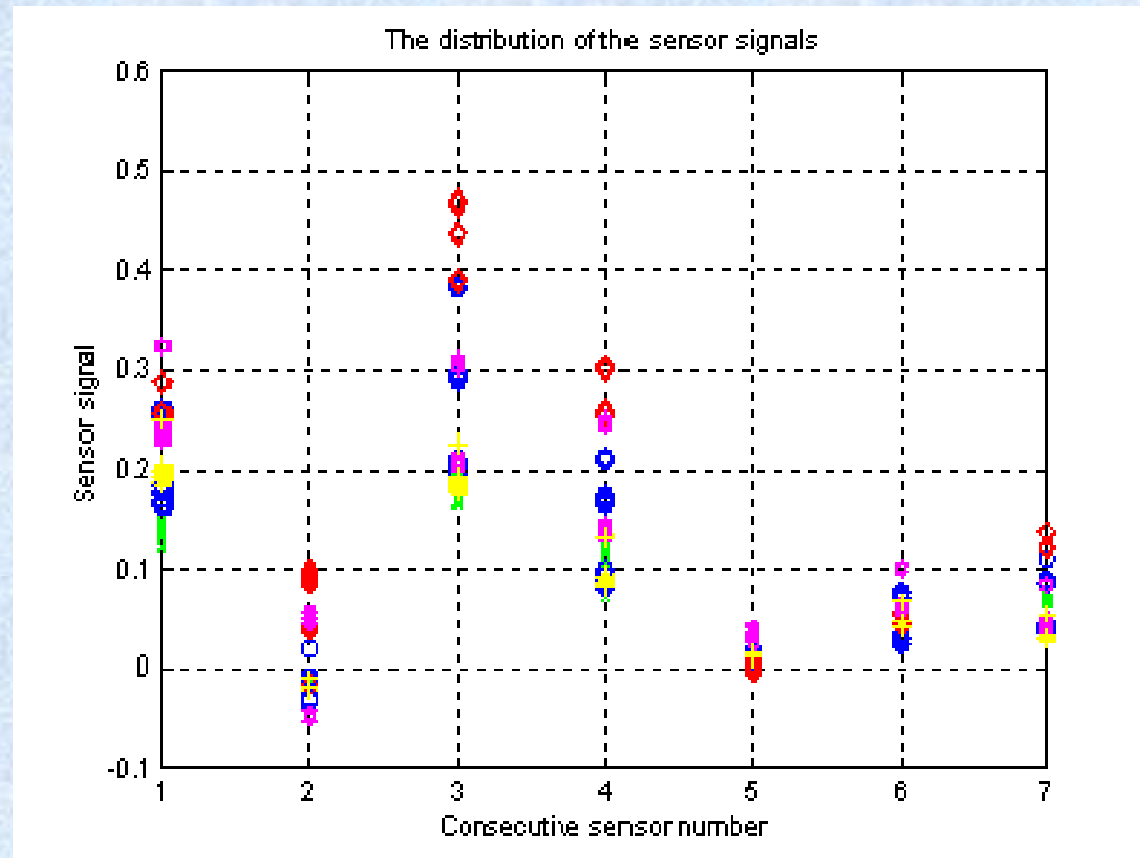
Układy pomiarowe

- 7 czujników tlenków metali
- Odpowiedź czujnika: względna zmiana jego rezystancji
$$\Delta R = (R - R_0) / R_0$$
- Dwie metody ustawienia poziomu odniesienia R_0 : przy „wążaniu” czystej wody lub jednego z typów mleka.
- Układ rozpoznawania i klasyfikacji: Program symulacji sieci SVM na PC

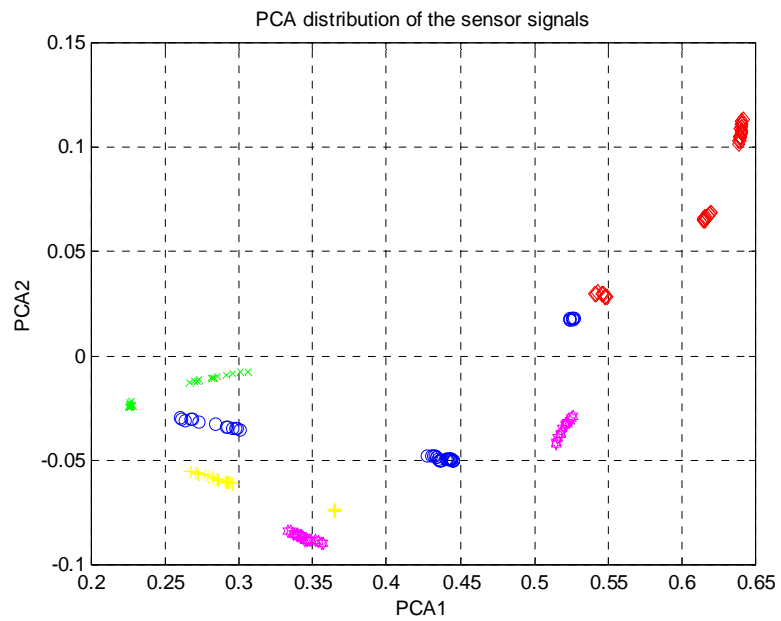
Rozpoznawanie różnego rodzaju mleka

- 4 rodzaje mleka o 3.2% tłuszczu: Łaciate, Nargo, Sielska Dolina i Rolmlecz
- Dla każdego rodzaju mleka: 180 próbek dostarczanych w 5 różnych dniach, w tym 90 losowo wybranych jest przeznaczonych do uczenia i 90 pozostałych – do testowania.
- Klasyfikator: Sieć SVM z liniową lub radialną funkcją jądra.

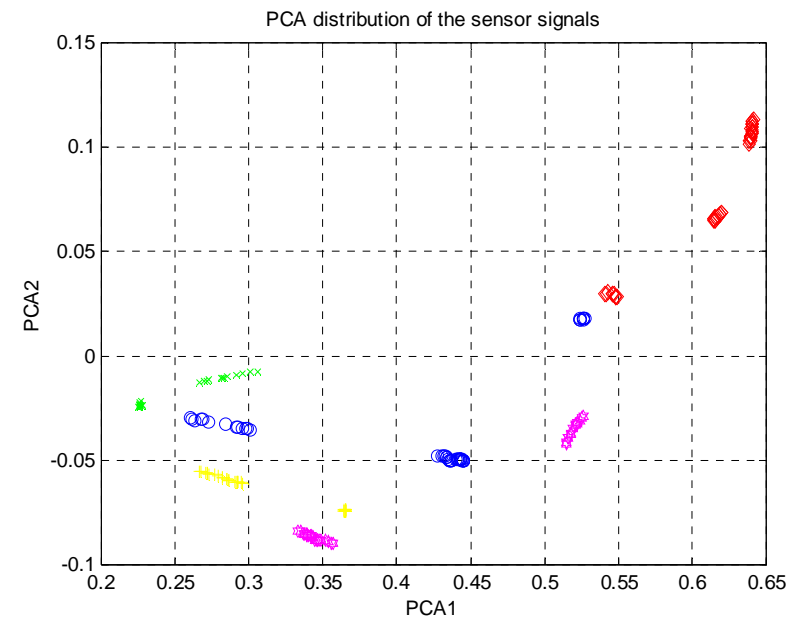
Rozkład sygnałów mierzonych



PCA sygnałów mierzonych



a)



b)

Rozpoznawanie mleka o różnych poziomach tłuszczu

- 1 rodzaj mleka (Łaciate) o różnych poziomach tłuszczu: 0%, 0.5%, 2% i 3.2%
- Dla każdego typu mleka: 180 próbek dostarczanych w 5 różnych dniach, w tym 90 losowo wybranych jest przeznaczonych do uczenia i 90 pozostałych – do testowania.
- Klasyfikator: Sieć SVM z liniową lub radialną funkcją jądra.

Wyniki numeryczne

	Najlepszy wynik	Parametry rozwiązania
Odniesienie – woda	100%	Radialne sieci SVM z 36 - 61 wektorami podtrzymującymi
Odniesienie – <i>4-te</i> mleko	100%	Liniowe sieci SVM z 3 - 11 wektorami podtrzymującymi

Wyniki numeryczne

	Najlepszy wynik	Parametry rozwiązania
Odniesienie – inne mleko	100%	Liniowe sieci SVM z 75 wektorami podtrzymującymi

Kierunki dalszych badań

- Ulepszenie układu pomiarowego:
 - Nowe czujniki
 - Zwiększenie czułości/selektywności, szybkości
 - Zmniejszenie rozmiarów
- Metody przetwarzania:
 - Obliczenie równoległe
 - Sieci neuronowe: z wbudowanym trybem uczenia
 - Sygnały wyjściowe: elektryczne, wizualne,...
- Układy symulujące inne zmysły:

Dziękuję za uwagę

Fisher Linear Discrimination

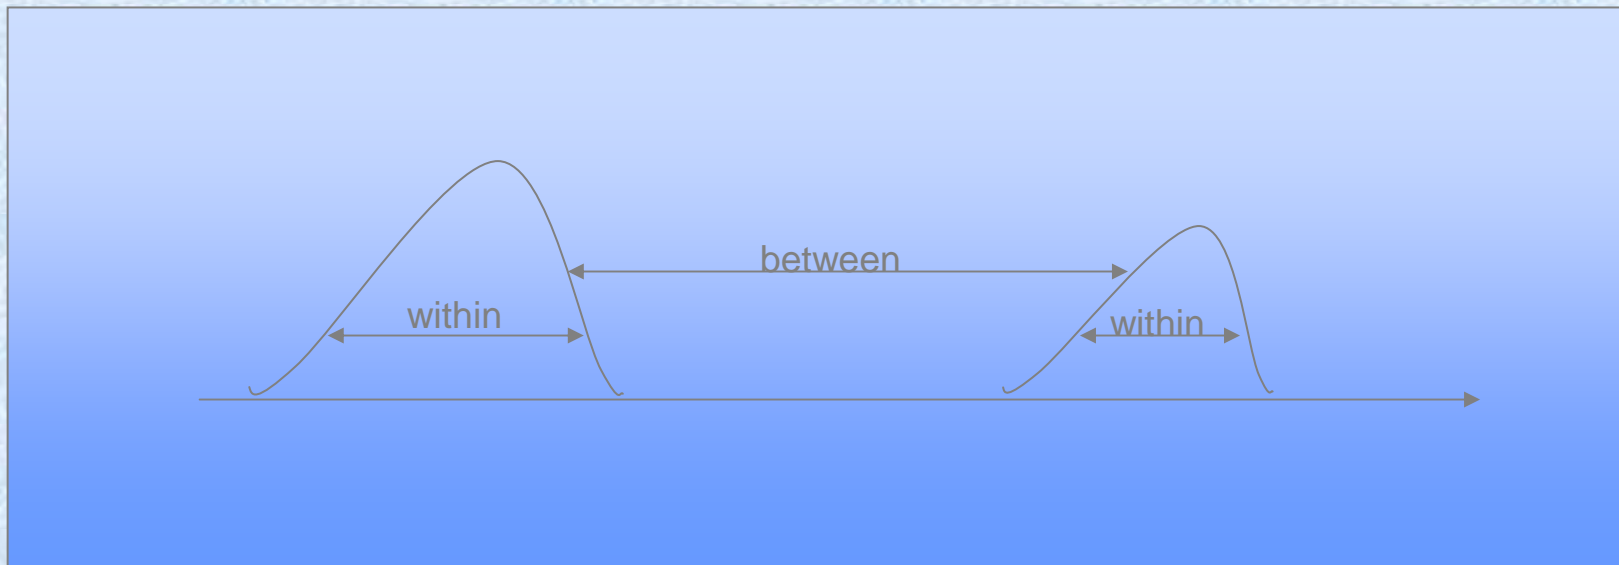
Suppose a case two classes

- Mean of these classes samples: $m_i = \frac{1}{n} \sum_{x \in X_i} x$
- Mean of the projected samples: $\tilde{m}_i = \frac{1}{n} \sum_{y \in Y_i} y = \frac{1}{n} \sum_{x \in X_i} w^t x = w^t m_i$
- 'Scatterness' of the projected samples: $\tilde{s}_i^2 = \sum_{y \in Y_i} (y - \tilde{m}_i)^2$
- Criterion function: $J(v) = \frac{|\tilde{m}_1 - \tilde{m}_2|^2}{\tilde{s}_1^2 + \tilde{s}_2^2}$

Fisher Linear Discrimination

- Optymalny wektor odpowiada maksimum stosunku „odległości między grup” do „szerokości” tych grup.

$$\frac{v^T B v}{v^T W v}$$



Fisher Linear Discrimination

- Criterion function should be maximized
- Present J as a function of a vector 'v'

$$W_i = \sum_{x \in X_i} (x - m_i)(x - m_i)^t$$

$$W = W_1 + W_2$$

$$\tilde{s}_i^2 = \sum_{x \in X_i} (v^t x - v^t m_i)^2 = \sum_{x \in X_i} v^t (x - m_i)(x - m_i)^t v = v^t W_i v$$

$$\tilde{s}_1^2 + \tilde{s}_2^2 = v^t W v$$

$$B = (m_1 - m_2)(m_1 - m_2)^t$$

$$(\tilde{m}_1 - \tilde{m}_2)^2 = (v^t m_1 - v^t m_2)^2 = v^t (m_1 - m_2)(m_1 - m_2)^t v = v^t B v$$

$$J(v) = \frac{v^t B v}{v^t W v}$$

Fisher Linear Discrimination

- Rzutowanie przestrzeni wejściowej X do przestrzeni o mniejszym wymiarze Y
 - Niech v – wektor opisujący przestrzeni Y .
 - Wyznaczyć rzuty wektorów wejściowych x na v .
 - Obliczyć „zdolność rozdzielania” wektora v dla danych wejściowych.
 - Wybrać wektor v o najlepszej „zdolności rozdzielania”

Fisher Linear Discrimination

- Przykład danych 2-wymiarowych rzutowanych na 1-wymiarowym wektorze.
- Wektor 'v' na rysunku po prawej stronie jest lepszym klasyfikatorem

