

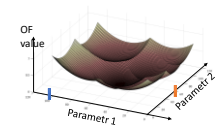
Inżynieria Mechatroniczna

Podstawy Sztucznej Inteligencji i Ucznienia Głębokiego:
3: Uczenie (maszynowe) na podstawie danych

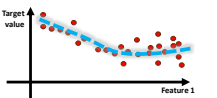
Ziemowit Dworakowski
 AGH w Krakowie

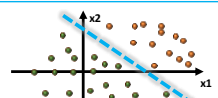
1

Co już wiemy? SD



Jak dotąd, wiemy jak znaleźć współrzędne minimum globalnego funkcji celu





Wiemy czym jest regresja i jak zaprojektować liniowe i nieliniowe modele regresyjne

Wiemy czym jest klasyfikacja i potrafimy zaproponować liniowy model klasyfikacyjny

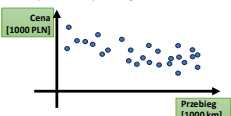
Dzisiaj nieco uogólnimy, spojrzymy na te problemy od strony przestrzeni cech i poznamy kilka nowych narzędzi i pojęć które przydadzą się po drodze

2

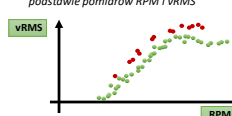
Przestrzeń parametrów a przestrzeń cech SD

Jeśli jakąś wartość mierzymy (lub z góry otrzymujemy) – jest to **cecha** (ang. **feature**). Jeśli mamy nad nią kontrolę i aktywnie poszukujemy jej konkretnej wartości - jest to **parametr** (ang. **parameter**).

Regresja:
 „Podaj spodziewaną cenę samochodu na podstawie przebiegu”



Klasyfikacja:
 „Podaj spodziewany stan turbiny wiatrowej na podstawie pomiarów RPM i vRMS”



3

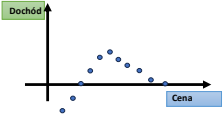
Przestrzeń parametrów a przestrzeń cech SD

Jeśli jakąś wartość **mierzmy** (lub z góry otrzymujemy) – jest to **cecha** (ang. **feature**). Jeśli mamy nad nią kontrolę i aktywnie poszukujemy jej konkretnej wartości – jest to **parametr** (ang. **parameter**).

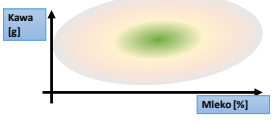
Dana zmienna może być parametrem lub cechą – w zależności od kontekstu

Optymalizację wykonujemy w przestrzeni parametrów. Regresję i klasyfikację w przestrzeni cech

Optymalizacja:
Znajdź taką cenę za samochód, by zmaksymalizować dochód.

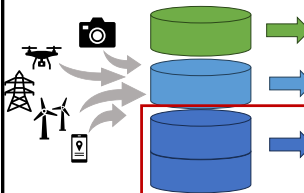


Optymalizacja:
„Podaj dla jakich proporcji kawy i mleka otrzymamy najsmaczniejsze latte”



4

Organizacja danych SD




Te podzbiory muszą być rozłączne!

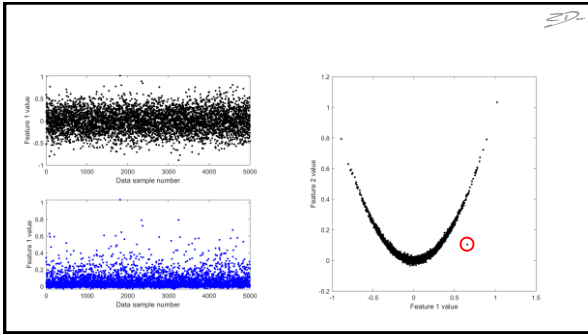
- Na podstawie podzbioru **testowego** oceniamy spodziewaną docelową skuteczność metod
- Na podstawie podzbioru **walidacyjnego** konfigurujemy modele i sprawdzamy czy wzorce są ogólne
- Na podstawie podzbioru **treningowego** uczymy się rozpoznawania wzorców w danych

Dzisiaj skupimy się wyłącznie na tym początkowym kroku, finalną konfigurację i weryfikację zostawiamy na kolejne okazje...


5



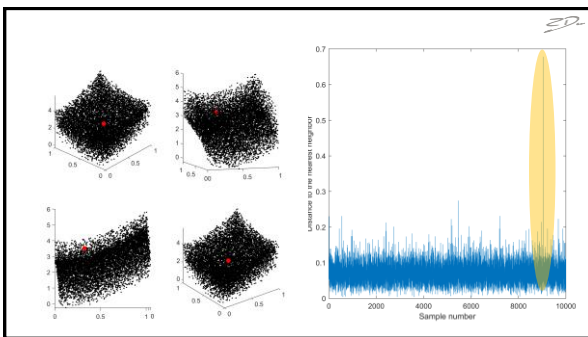
6



7



8




9

SD

Wizualizacje danych mogą być mylące...

Więc – chcemy zaprojektować takie metody reprezentowania danych, by być w stanie automatycznie rozpoznać wzorce w wielowymiarowej przestrzeni cech

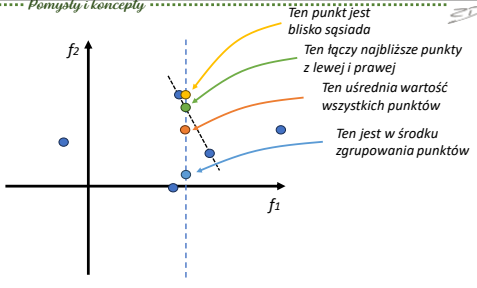


- Zbudować reguły określające gdzie można się spodziewać obecności danych
- Zorganizować dane poprzez rozpoznanie zależności między nimi i ew. przynależności do podkategorii

10

SD

Pomysły i koncepty

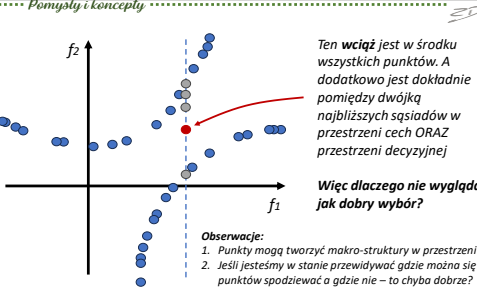


- Ten punkt jest blisko sąsiada
- Ten łączy najbliższe punkty z lewej i prawej
- Ten uśrednia wartość wszystkich punktów
- Ten jest w środku zgrupowania punktów

11

SD

Pomysły i koncepty



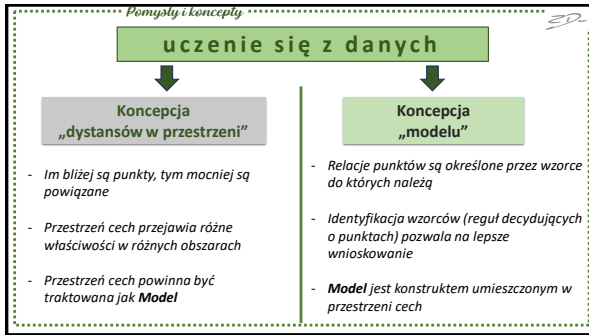
Ten **wciąż** jest w środku wszystkich punktów. A dodatkowo jest dokładnie pomiędzy dwójką najbliższych sąsiadów w przestrzeni cech ORAZ przestrzeni decyzyjnej

Więc dlaczego nie wygląda jak dobry wybór?


Obserwacje:

1. Punkty mogą tworzyć makro-struktury w przestrzeni
2. Jeśli jesteśmy w stanie przewidywać gdzie można się punktów spodziewać a gdzie nie – to chyba dobrze?
3. Powinniśmy być w stanie aktualizować nasz model wraz z dostępem do nowych danych

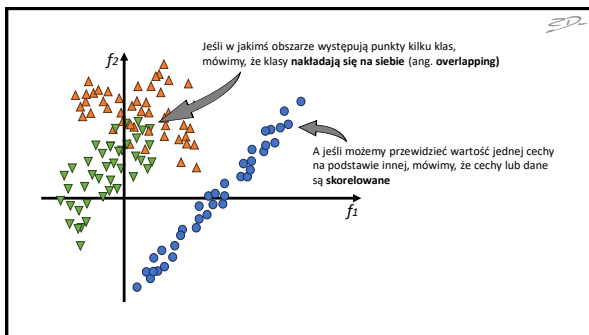
12



13



14



15

Metoda k-najbliższych sąsiadów (k Nearest Neighbor classifier, kNN) SD

1. Znajdź k (nieparzyste) najbliższych sąsiadów klasyfikowanego punktu
2. Przypisz punktowi najpopularniejszą etykietę

Jak metoda zareaguje na anomalie?
 ↓
 k powinno być ≥ 3

+ Intuicyjna
 + Prosta w implementacji
 + Prosta w konfiguracji

- Wymaga dużo pamięci
 - Wymaga dużo mocy obliczeniowej (powolna)
 - Złe skaluje się w wysokowymiarową przestrzeń cech

16

Regresja z zastosowaniem metody kNN SD

... znamy już coś bardzo podobnego!
 (Prawie dokładnie tak samo działa estymator lokalnie liniowy)

17


Rozwiązania bazujące na klasteryzacji SD

1. Zaczynamy od nieoetykietowanych danych (to metoda **nienadzorowana**)
2. Znajdźmy klastry danych
3. „Pokolorujmy” klastry na podstawie wybranych oetykietowanych punktów (np. wybierając większośćową etykietę)

18

Rozwiązania bazujące na klasteryzacji

SD




1. Zaczynamy od nieoetykietowanych danych (to metoda **nienadzorowana**)
2. **Znajdźmy klastry danych**
3. „Pokolorujmy” klastry na podstawie wybranych oetykietowanych punktów (np. wybierając **większościową etykietę**)
4. Dla nowych danych sprawdzimy do których klastrów należą punkty i klasyfikujemy je odpowiednio

19

Algorytm centroidów (K-means clustering, KMC)

SD




+ Intuicyjny
+ Jedna z najprostszych metod klasteryzacji

- Musimy wiedzieć, ile klastrów jest w danych
- Granice klastrów nie mają dobrego uzasadnienia
- Metoda źle skaluje się w przestrzeń wielowymiarową

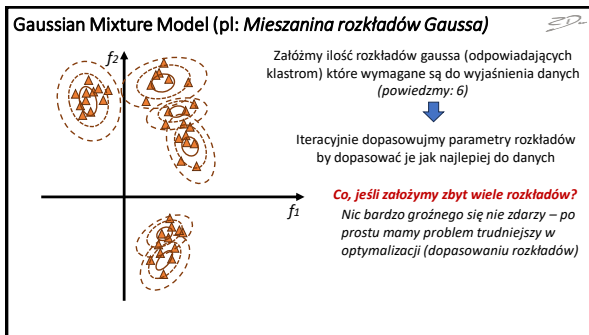
- Założmy ilość klastrów, wybierzmy ich centroidy losowo
- ↓
- Przypiszmy punkty do klastrów bazując na ich dystansie do centroidu
- ↓
- Przeliczmy położenia centroidów na podstawie przypisanych do nich punktów
- ↓
- Powtarzajmy, dopóki położenia centroidów się zmieniają

20




- Większość rzeczywistych rozkładów danych przypomina rozkład gaussa (normalny)
- Więc często rozsądne jest założenie z góry, iż **rozkład danych jest normalny**
- Wtedy możemy dopasować do danych **wielowymiarowy rozkład normalny** który najlepiej wytłumaczy ich położenie
- ...A definiujemy go za pomocą **wektora średniej** i **macierzy kowariancji**


21



22



23



24

Pytania do powtórki:

SD

1. Przedstaw jak dane eksperymentalne dzielone są na podzbiory, nazwij te podzbiory i wyjaśnij do czego są używane
2. Wyjaśnij separowalność liniową i jej brak, anomalie, klastry i korelację danych. Zaprezentuj graficzne ilustracje w.w. pojęć
3. Wyjaśnij jak działa metoda kNN w klasyfikacji (podaj też wady i zalety)
4. Wyjaśnij na czym polega klasteryzacja danych, wyjaśnij metodę centroidów z jej wadami i zaletami
5. Wyjaśnij jak działa metoda mieszaniny rozkładów Gaussa – z graficznym przykładem Gaussianów dopasowanych do klastrów danych. Przedstaw wady i zalety tej metody
