

Statystyka II. Egzamin komputerowy 04.09.2007.

1. Wczytaj z archiwum *MacierzePot14_3kol.zip* potencjały kontaktowe (PK), czyli 12 symetrycznych macierzy 20×20 opisujących oddziaływania 210 par aminokwasów w białkach. PK są zapisane w plikach trójkolumnowych tak, że w pierwszej kolumnie znajduje się numer wiersza, w drugiej – numer kolumny, a w trzeciej - wartość odpowiedniego elementu macierzy PK o tych współrzędnych. Napisz ogólną funkcję `three2Vec`, która przekształca plik trójkolumnowy na wektor złożony z elementów macierzy PK należących do jej górnej części (ewentualnie dolnej) oraz przekątnej. Ze zbioru wektorów $\mathbf{x}_1, \dots, \mathbf{x}_{12}$ otrzymanych z 12 PK, zbuduj macierz danych $X = [\mathbf{x}_1, \dots, \mathbf{x}_{12}]$. Sprawdź, czy w zbiorze X -- 210 obserwacji 12-wymiarowych są obserwacje odstające.
2. Zbuduj model analizy wariancji dla danych `immer` z biblioteki `MASS`. W modelu tym zmienną objaśnianą jest $Y = (Y1+Y2)/2$ - średni plon jęczmienia z lat 1931-32. Dobierz transformację zmienną Y korzystając z funkcji `boxcox` i `logtrans` oraz wykonaj automatyczną selekcję zmiennych.
3. Na danych `crabs` z biblioteki `MASS`, porównaj w eksperymencie weryfikacji krzyżowej (5/6 danych do trenowania) metody klasyfikacji zaimplementowane w funkcjach `rpart`, `nnet` oraz regresję logistyczną. Cecha przewidywana przyjmuje dwie wartości: $y = \text{ifelse}(X[,1] == "B", 1, 0)$. Policz współczynnik Goodmana-Kruskala między y oraz y_pred dla tych trzech metod.
4. Napisz funkcję rysującą wykres konturowy 2-wymiarowej gęstości $f(x,y)$ tak, że warstwice ograniczają obszary o zadanych prawdopodobieństwach $p = (p_1, \dots, p_k)$. Na przykład, jeśli $p = c(1,2,3,4)/5$, to pierwsza warstwica jest zadana przez zbiór $\{(x, y) : f(x, y) = z, P(f(x, y) \geq z) = 1/5\}$ dla pewnego z . Policz gęstość (FL , RW) za pomocą `kde2d` i narysuj warstwice dla danego wyżej p na danych `crabs`.
5. Załóżmy, że czas życia żarówki (C) ma rozkład gamma z parametrami: skala=2, kształt=4. Wylosuj 1000 niezależnych obserwacji z tego rozkładu i oszacuj prawdopodobieństwo, że C jest nie mniejszy niż $d = 1.5 * z_{0.25}$, gdzie $z_{0.25}$ jest kwantylem próbkowym rzędu 0.25 tego rozkładu (wskazówka: funkcja `quantile` oblicza kwantyle próbkowe). Policz d numerycznie (bez losowania).