

UE Statistische Mustererkennung
WS 2021
Angaben zur 3ten Aufgabengruppe

1 Aufgabe UE-III.1

1.1

- a) Generieren Sie eine Stichprobe vom Umfang 300 für die bivariate Normalverteilung mit Mittelwert $(4, 7)^T$ und Varianzen bzw. Korrelationskoeffizienten $\sigma_{11} = 12, \sigma_{22} = 2, \rho_{12} = -0.5$. Gehen Sie dabei wie folgt vor:
- Berechnen Sie die Eigenwertzerlegung der Kovarianzmatrix, und aus dieser die inverse *whitening*-Transformation.
 - Generieren Sie 600 unabhängig $N(0, 1)$ verteilte Zufallswerte, und ordnen Sie diese in einer 2×300 -Matrix an; dies entspricht einer Stichprobe vom Umfang 300 einer bivariaten Normalverteilung mit dekorrelierten und z-standardisierten Variablen X, Y .
 - Wenden Sie die inverse *whitening* Transformation auf die obige Stichprobe an.
- b) Schätzen Sie aus der Stichprobe das Mittel, die Kovarianzmatrix sowie die Korrelationsmatrix (berechnet sich aus der Kovarianzmatrix, indem man jedes Element durch das Produkt der korrespondierenden Standardabweichungen dividiert).
- b) Vergleichen Sie Ihre Ergebnisse mit den wahren Verteilungsparametern aus dem obigen Teilbeispiel, sowie mit der Kovarianz- resp. Korrelationsmatrixschätzung des von Ihnen verwendeten Softwarepaketes.

2 Aufgabe UE-III.2

Plotten Sie den *Rayleigh-Quotienten*

$$r(\mathbf{w}) = \frac{\mathbf{w}^T \mathbf{A} \mathbf{w}}{\mathbf{w}^T \mathbf{w}} \quad (1)$$

sowohl für die Kovarianz- als auch die Korrelations-Matrix in Beispiel III.1, indem Sie wie folgt vorgehen: lassen Sie den Richtungsvektor \mathbf{w} von 0 bis 360 Grad rotieren und geben Sie die mit dem Wert des Rayleigh-Quotienten skalierten Richtungsvektoren $r(\mathbf{w}) \frac{\mathbf{w}}{\|\mathbf{w}\|}$ aus (dies ist eine parametrische Kurve im \mathbb{R}^2).

Ergänzen Sie die Darstellung der Kurven durch die mit ihren korrespondierenden Eigenwerten skalierten Eigenvektoren der Kovarianz- bzw. Korrelationsmatrix.

3 Aufgabe UE-III.3

Die Dateien namens *ldaTrain.txt* und *ldaTest.txt* enthalten je 500 2-dimensionale Merkmalsvektoren. Die ersten 200 Punkte gehören zur Klasse ω_1 , die nächsten 200 Punkte zur Klasse ω_2 und die letzten 100 zur Klasse ω_3 .

- a) Lesen Sie die Datei *ldaTrain.txt* ein und fassen Sie die 500 Punkte als Zufallsstichprobe einer *mixture distribution* dreier bivariater Normalverteilungen auf. Trainieren Sie einen linearen Klassifikator unter der Annahme, daß die Merkmale für alle drei Klassen normalverteilt mit identischen Kovarianzmatrizen sind, mittels LDA. Schätzen Sie dazu die *a priori*-Wahrscheinlichkeiten, Klassen-Mittel und die gemeinsame Kovarianzmatrix aus den Daten. Um eine gemeinsame (gepoolte) Kovarianzschätzung für alle Klassen zu erhalten, verwenden Sie

$$\hat{\mathbf{C}} = \frac{1}{(\sum_{j=1}^c N_j) - c} \sum_{j=1}^c \sum_{i=1}^{N_j} (\mathbf{x}_i^{(j)} - \hat{\mathbf{m}}^{(j)})(\mathbf{x}_i^{(j)} - \hat{\mathbf{m}}^{(j)})^T,$$

wobei c die Anzahl der Klassen, $\mathbf{x}_i^{(j)}$ das i -te Stichprobenelement, $\hat{\mathbf{m}}^{(j)}$ das arithmetische Mittel und N_j die Anzahl der Stichprobenelemente der Klasse $\omega = j$ bezeichnet.

- b) Plotten Sie die Verteilungen (z.B. als Scatterplot) und die mittels LDA gefundene Entscheidungsgrenze.
- c) Berechnen Sie sowohl den Trainingsfehler als auch den Testfehler (letzteren auf der Testmenge in *ldaTest.txt*).

4 Aufgabe UE-III.4

Wenn die N Beobachtungen Y_i iid und somit unkorreliert sind, ist die Varianz des Stichprobenmittels \bar{Y} bekanntlich durch σ^2/N gegeben, wobei $\sigma^2 = \text{Var}[Y]$ die allen Beobachtungen zugrundeliegende Populationsvarianz bezeichnet.

Wir nehmen nun an, daß die Beobachtungen korreliert sind, d.h. für die Kovarianzmatrix der Beobachtungen $\mathbf{\Sigma} = (\sigma_{ij})_{1 \leq i, j \leq N}$ gelte

$$\sigma_{ij} = \begin{cases} \rho\sigma^2, & \text{falls } i \neq j \\ \sigma^2, & \text{falls } i = j \end{cases} . \quad (2)$$

Berechnen Sie mittels Lemma 2 (Vorwärtstransport der Varianz) die Varianz des Stichprobenmittels für korrelierte Beobachtungen. Was geschieht im Extremfall $\rho = 1$?