

## Übungen zur Vorlesung „Hidden Markov Models“

### Blatt 2

**Abgabetermin:** Dienstag, 31.10.2023, bis 14:15 Uhr in der Vorlesung.  
 (Bitte nur maximal zu zweit abgeben.)

**Aufgabe 1** (4 Punkte)

Sei  $(\varepsilon_k)_{k \geq 1}$  eine reellwertige iid-Folge. Für  $p \in \mathbb{N}$  seien  $a_1, \dots, a_p \in \mathbb{R}$ ,  $a_p \neq 0$ . Einen Prozess  $(X_k)_{k \geq 0}$  mit  $X_0 = \dots = X_{p-1} = 0$ , welcher der Rekursion

$$X_n = \sum_{k=1}^p a_k X_{n-k} + \varepsilon_n \quad (n \geq p)$$

genügt, bezeichnen wir als AR(p)-Prozess mit Startwert  $X_0 = \dots = X_{p-1} = 0$ . Beweisen Sie:

- a) Für  $p > 1$  besitzt ein AR(p)-Prozess nicht die Markov-Eigenschaft.
- b) Durch geeignete Vegrößerung des Zustandsraumes kann man den AR(p)-Prozess dennoch als Markovprozess darstellen.

**Aufgabe 2** (4 Punkte)

Seien  $(X_k)_{k \geq 0}$  und  $(Y_k)_{k \geq 0}$  zwei unabhängige AR(1)-Prozesse mit Startwert  $X_0 = Y_0 = 0$ . Beweisen Sie, dass  $(X_k, Y_k)_{k \geq 0}$  zwar eine bivariate Markovkette aber kein Hidden-Markov-Modell ist.

**Aufgabe 3** (4 Punkte)

DNA-Sequenzen kodieren genetische Information in vier Buchstaben,  $A, C, G, T$ . Jedoch kann die Art und Weise, in der ein und dasselbe Merkmal kodiert ist, bei verschiedenen Individuen deutlich variieren. Beispielsweise kodieren die folgenden fünf Abfolgen dasselbe Merkmal:  $ACAATG, AGAATC, ACACAGC, ACCGATC, TCAATGATC$ . Um das ihnen gemeinsame Muster hervorzubringen, sind sie in folgender Tabelle angeordnet:

l1	l2	l3	li	li	li	l4	l5	l6
A	C	A	-	-	-	A	T	G
A	G	A	-	-	-	A	T	C
A	C	A	C	-	-	A	G	C
A	C	C	G	-	-	A	T	C
T	C	A	A	T	G	A	T	C

Offenbar variiert das Basismuster  $ACAATC$  auf zwei Weisen: Die individuelle Abfolge  $l1 - l6$  kann eine Mutation enthalten und zusätzliche beliebige Symbole  $li$  können in die Mitte der Abfolge eingefügt sein.

Modellieren Sie diese Muster als Hidden-Markov-Modell mit den Zustandsräumen  $Y = \{A, C, G, T\}$  und  $X = \{l1, \dots, l6, li, le\}$ , wobei  $Q(l6, \{le\}) = Q(le, \{le\}) = 1$  gelte ( $le$  ist ein sogenannter terminaler Zustand). Sei weiter  $G(le, \{y\}) = 1/4$  für alle  $y \in Y$ . Bestimmen Sie den Übergangskern  $Q$  des Signalprozesses und den Beobachtungskern  $G$ .