

30. Mai 2007	Prüfung aus Einführung in die Mustererkennung — SS 2006	11.00 – 12.30
Matr.Nummer:	Nachname:	
Kennzahl:	Vorname:	

Bei der vorliegenden Prüfung können Sie eine maximale Anzahl von 30 Punkten erreichen. Bitte verwenden Sie den für die Beantwortung der Frage vorgesehenen Platz und beantworten Sie die folgenden Fragen kurz aber aussagekräftig. Sie können die Fragen auf Englisch oder Deutsch beantworten. **Keine Unterlagen sind erlaubt.**

1 Kurze Fragen

1. Ist das Multilayer Perceptron (MLP) neuronale Netz ein überwachtes oder unüberwachtes Lernverfahren? Die nicht-passende Antwort durchstreichen. (1 Punkt)

Überwachtes Verfahren / Unüberwachtes Verfahren

Begründung: weil das Trainingsset aus Eingabe- und den zugehörigen Ausgabewerten besteht.

2. Ist Klassifikation anhand der Mahalanobis Distanz ein parametrisches oder nicht-parametrisches Verfahren? Die nicht-passende Antwort durchstreichen. (1 Punkt)

Parametrisches Verfahren / Nicht-parametrisches Verfahren

Begründung: weil eine gauss-Kurve bekannt ist

3. Die Aktivierungsfunktion in einem Backpropagation neuronalen Netz muss

eine tanh Funktion / differenzierbar / eine Signum-Funktion / integrierbar

sein. Die nicht-passenden Antworten durchstreichen. (1 Punkt)

2 Rechenbeispiele

1. Sie bekommen den Auftrag, eine Maschine zu entwickeln, die automatisch zwischen zwei wiederverwertbaren Müllarten, Glasflaschen (Klasse 1, $\omega = 1$) und Plastikflaschen (Klasse 2, $\omega = 2$), unterscheidet. Ein diskretes Helligkeitsmerkmal x , das 3 Werte annehmen kann, wird für jede Flasche gemessen ($x = 1, 2$ oder 3). Die *a priori* Klassenwahrscheinlichkeiten sind: $P(\omega = 1) = 0.4$ und $P(\omega = 2) = 0.6$. Vom Trainingsset wird die folgende Merkmalsverteilung für jede Klasse $P(x = i|\omega = j)$ experimentell gemessen:

i	1	2	3
$P(x = i \omega = 1)$	0.8	0.2	0.0
$P(x = i \omega = 2)$	0.4	0.3	0.3

- (a) Berechnen Sie $P(x = i)$ für $i = 1, 2, 3$. Füllen Sie die folgende Tabelle aus (1 Punkt):

$P(x=1) = 0.8 \times 0.4 + 0.4 \times 0.6 = 0.56$
 $P(x=2) = 0.2 \times 0.4 + 0.3 \times 0.6 = 0.26$
 $P(x=3) = 0.0 \times 0.4 + 0.3 \times 0.6 = 0.18$

i	1	2	3
$P(x = i)$	0.56	0.26	0.18

- (b) Wie berechnen sich gemäß Bayes-Theorem die *a posteriori* Wahrscheinlichkeiten (posteriors)? (1 Punkt)

$P(\omega=1|x=1) = \frac{0.8 \times 0.4}{0.56} = 0.571$
 $P(\omega=2|x=1) = \frac{0.4 \times 0.6}{0.56} = 0.429$

- (c) Berechnen Sie die *a posteriori* Wahrscheinlichkeiten und füllen Sie die folgende Tabelle aus (1 Punkt):

$P(\omega=1|x=1) = \frac{0.8 \times 0.4}{0.56} = 0.571$
 $P(\omega=2|x=1) = \frac{0.4 \times 0.6}{0.56} = 0.429$

j	1	2
$P(\omega = j x = 1)$	0.571	0.429
$P(\omega = j x = 2)$	0.222	0.778
$P(\omega = j x = 3)$	0	1

- (d) Welche Klasse soll laut Bayes-Entscheidungsregel (*Bayes Decision Rule*) und der oben ausgerechneten *a posteriori* Klassenwahrscheinlichkeiten für die drei möglichen x -Werte gewählt werden? Was ist der korrespondierende *conditional error* $P(\text{error}|x)$?
 Füllen Sie die folgende Tabelle aus (1 Punkt):

	Klasse (1 oder 2)	$P(\text{error} x)$
$x = 1$	1	0,45
$x = 2$	2	0,21
$x = 3$	2	0,19

- (e) Berechnen Sie die Fehlerrate $P(\text{error})$ für dieses Beispiel. Schreiben Sie die berechnete Fehlerrate ins Rechteck unten. (1 Punkt)

$$P(\text{error}) = \sum P(\text{error}|x) P(x=1)$$

$$P(\text{error}) = 0,45 \cdot 0,56 + 0,21 \cdot 0,19 + 0,19 \cdot 0,25 = 0,406$$

Fehlerrate:

- (f) Beweisen Sie, dass die Bayes-Entscheidungsregel im Zwei-Klassen Fall die Fehlerrate $P(\text{error})$ immer minimiert. (2 Punkte)

Wenn wir zwei Klassen haben, dann ist die Fehlerrate $P(\text{error})$ die Wahrscheinlichkeit, dass eine Beobachtung x in die falsche Klasse $k \neq \hat{k}$ (wobei \hat{k} die wahre Klasse ist) fällt.
 Die Fehlerrate ist also $P(\text{error}) = \sum_{k \neq \hat{k}} P(x \in k | \text{Klasse } \hat{k})$.
 Die Bayes-Entscheidungsregel wählt die Klasse \hat{k} , die die Wahrscheinlichkeit $P(x \in \hat{k} | \text{Klasse } \hat{k})$ maximiert.
 Da die Fehlerrate $P(\text{error})$ die Wahrscheinlichkeit ist, dass eine Beobachtung x in die falsche Klasse $k \neq \hat{k}$ fällt, ist die Fehlerrate $P(\text{error})$ immer minimiert, wenn die Bayes-Entscheidungsregel angewendet wird.

2. Sie haben zwei Klassen und wollen die Entscheidungsgrenze zwischen diesen zwei Klassen berechnen. Das Trainingsset für jede Klasse besteht aus 4 zwei-dimensionalen Vektoren. Die Trainingsvektoren für Klasse 1 sind:

$$\mathbf{x}_{11} = \begin{pmatrix} 1 \\ 3 \end{pmatrix}, \mathbf{x}_{12} = \begin{pmatrix} 3 \\ 3 \end{pmatrix}, \mathbf{x}_{13} = \begin{pmatrix} 2 \\ 2 \end{pmatrix}, \mathbf{x}_{14} = \begin{pmatrix} 2 \\ 4 \end{pmatrix} \quad (1)$$

und die Trainingsvektoren für Klasse 2 sind:

$$\mathbf{x}_{21} = \begin{pmatrix} 5 \\ 3 \end{pmatrix}, \mathbf{x}_{22} = \begin{pmatrix} 7 \\ 3 \end{pmatrix}, \mathbf{x}_{23} = \begin{pmatrix} 6 \\ 2 \end{pmatrix}, \mathbf{x}_{24} = \begin{pmatrix} 6 \\ 4 \end{pmatrix} \quad (2)$$

- (a) Berechnen Sie die geschätzten Mittelwertvektoren $\hat{\mu}_j$ für diese zwei Klassen. Schreiben Sie diese Vektoren in die unteren Rechtecke. (1 Punkt)

Mittelwertvektor $\hat{\mu}_1 =$ Mittelwertvektor $\hat{\mu}_2 =$

- (b) Berechnen Sie die geschätzte Kovarianzmatrix $\hat{\Sigma}_1$ für Klasse 1. Schreiben Sie diese Matrix ins Rechteck auf der nächsten Seite. (1 Punkt)

Kovarianzmatrix $\hat{\Sigma}_1 =$

(c) Sie modellieren die Klassen durch zwei-dimensionale Gauß'sche Verteilungen:

$$p(\mathbf{x}|\omega_j) = \frac{1}{(2\pi)^{\frac{a}{2}} |\hat{\Sigma}_j|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} (\mathbf{x} - \hat{\mu}_j)^T \hat{\Sigma}_j^{-1} (\mathbf{x} - \hat{\mu}_j) \right] \quad (3)$$

wobei $a = 2$. Schreiben Sie die Diskriminanten-Funktion $g_j(\mathbf{x}) = \ln p(\omega_j|\mathbf{x})$ hier aus (die Gauß'sche Verteilung für $p(\mathbf{x}|\omega_j)$ soll auch in diesen Ausdruck hineingenommen werden). N.B. Der Ausdruck soll eine Funktion von $\hat{\mu}_j$, $\hat{\Sigma}_j$, ω_j , $P(\omega_j)$, $p(\mathbf{x})$ und \mathbf{x} sein. Klassen-spezifische Werte sollen nicht verwendet werden. (1 Punkt)

- (d) Warum kann man die Terme: $-\ln 2\pi - \ln p(\mathbf{x})$ auslassen, ohne dass die Entscheidungsregionen und Entscheidungsgrenzen sich ändern? (1 Punkt)

- (e) Sie nehmen an, dass $P(\omega_1) = P(\omega_2) = \frac{1}{2}$. Die Diskriminanten-Funktionen für die zwei Klassen schauen so aus:

$$g_1(\mathbf{x}) = -\frac{3}{4}x_1^2 + 3x_1 - \frac{3}{4}x_2^2 + \frac{9}{2}x_2 - \frac{39}{4} - \frac{1}{2} \ln\left(\frac{4}{9}\right) + \ln\left(\frac{1}{2}\right) \quad (4)$$

$$g_2(\mathbf{x}) = -\frac{3}{4}x_1^2 + 9x_1 - \frac{3}{4}x_2^2 + \frac{9}{2}x_2 - \frac{135}{4} - \frac{1}{2} \ln\left(\frac{4}{9}\right) + \ln\left(\frac{1}{2}\right) \quad (5)$$

wobei x_1 und x_2 die zwei Komponenten vom einem beliebigen Vektor \mathbf{x} sind. Berechnen Sie den Ausdruck für die Entscheidungsgrenze. (1 Punkt)

3 Detaillierte Fragen

1. Dieser Datensatz soll für das Training eines Entscheidungsbaumes verwendet werden. Der Baum soll prognostizieren ob eine Person glücklich (G) oder unglücklich (U) ist, basiert auf der Farbe der Schuhe, ob eine Perücke getragen wird und der Anzahl von Ohren.

Farbe	Perücke	Anzahl von Ohren	Emotion
G	J	2	U
G	N	2	U
G	N	2	U
B	N	2	U
B	N	2	G
R	N	2	G
R	N	2	G
R	N	2	G
R	J	3	G

Zeichnen Sie einen vollständigen binären Entscheidungsbaum für diese Daten (Sie sollen annehmen, dass keine *Pruning* gemacht wird). (3 Punkte)

Handwritten notes:
Anzahl Ohren
Farbe
Perücke
Emotion
37 20 46

2. Wie wird Klassifikation anhand der Mahalanobis Distanz durchgeführt? Schreiben Sie den Ausdruck für die Mahalanobis Distanz. Wie werden die Parameter während der Trainingsphase geschätzt? Auf dem Diagramm sind Trainingsvektoren, die zu einer Klasse gehören, geplottet. Zeichnen Sie ein paar Konturlinien, die einem konstanten Wert für die Mahalanobis Distanz ab dieser Klasse entsprechen (die Konturlinien sollen ungefähr die richtige Form zeigen, aber müssen nicht genau sein). (3 Punkte)

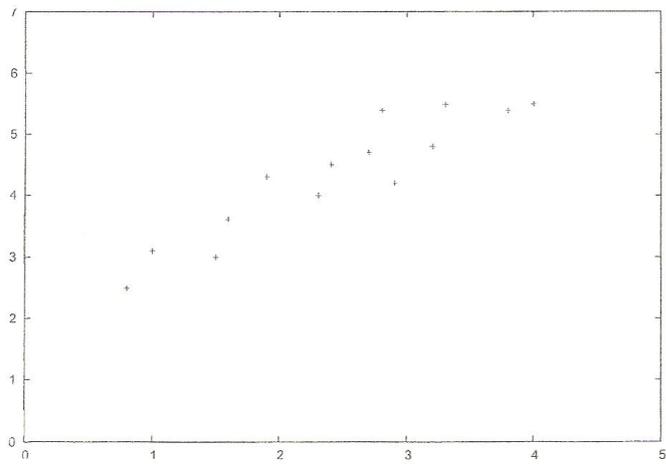
Definiere Distanz Mittelwert μ Kovarianz

Bestimmungen (nicht μ) sind: Umwandlungs- Zufallsvektor $x \sim N(\mu, \Sigma)$ und Mittelwert μ Kovarianz Σ

$$D(x) = \frac{1}{\sqrt{|\Sigma|}} \sqrt{(x - \mu)^T \Sigma^{-1} (x - \mu)}$$

Standardabweichung

Das ist ein...
 Punkt zeigt die...
 Distanz...



4 Aufsatz

Wählen Sie eines der folgenden Themen und schreiben Sie 150–200 Wörter darüber (6 Punkte).
Die Themen sind:

1. Parametrische und nicht-parametrische Verfahren für die Schätzung von Wahrscheinlichkeitsdichtefunktionen.
2. Bias, Varianz und Generalisierungsfähigkeit.
3. Merkmalsextraktion in der Biometrie.

① Parametrische Verfahren: keine Annahme über die pdf Funktion

② Parametrische Verfahren: Annahme über die Form der pdf Funktion
z.B. Gaußsche Linie

Wir wählen die Parameter der Kurve

Vorteil: hat die Form der pdf Funktion \rightarrow weniger

Parameter zu schätzen und oft können wir die Parameter

auswendig

③ PCA Gesichtserkennung

④ Hostile graph matching: Ein Graph und Knoten werden in jedem Knoten

zugeordnet ist der Inhalt eines Graphen verändert
Diese Graphen sind ein Bild von Gesichtern, eingeteilt nach einem
Bildschirm zu einem Hostile Graph zwischen dem Bildschirm und
anderen in die Hostile Graphen eingeteilt