



max planck institut
informatik

Ideen der Informatik

Maschinelles Lernen

Kurt Mehlhorn

Adrian Neumann

Max-Planck-Institut für Informatik

Übersicht

- Lernen: Begriff
- Beispiele für den Stand der Kunst
- Spamerkennung
- Handschriftenerkennung
 - mit und ohne Trainingsdaten
- Neuronale Netzwerke
 - Maschinelles Sehen



Lernen

- Fähigkeit, Verhalten zu verbessern auf Grund von Erfahrungen
- Verallgemeinern von Erfahrungen
- Informatik: Programmieren durch Beispiele anstatt durch Angabe eines Programms
- Ein Lernalgorithmus entwickelt das Programm aus (vielen) Daten

Typische Anwendungen

- Klassifikation Spam versus Ham, Ziffernerkennung, Verkehrszeichen-erkennung, Objekte auf Bildern, Identifikation von Personen auf Bildern, Handlungen aus Videosequenzen.
- Robotersteuerung, lerne Autofahren
- Spracherkennung, Sprachsteuerung

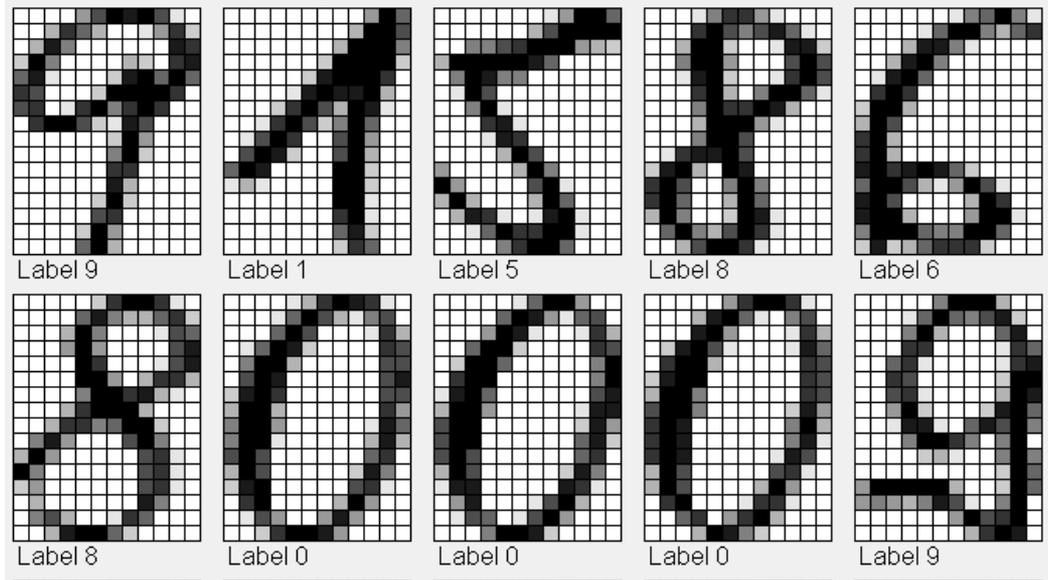
Potential

- Suchmaschinen mit Bild/Sprach-Anfragen
- Personenerkennung auf Videos
- XXX mit gesprochener Sprache
- Selbstfahrende Autos
- Bessere Benutzerschnittstellen
- Maschinelle Übersetzung



Arten von Lernen

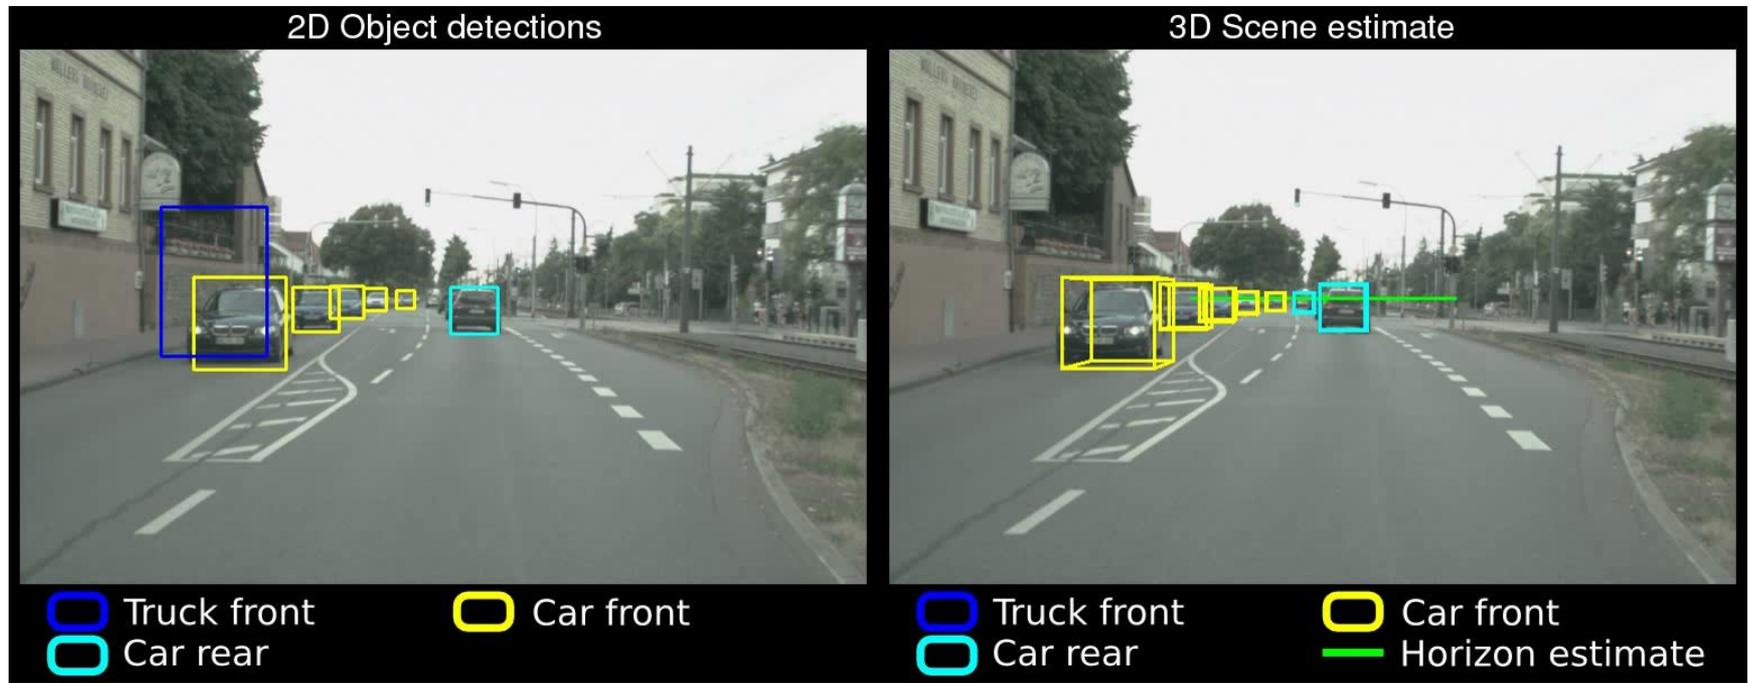
- Supervised: mit Trainingsdaten oder sogar mit Lehrer



- Unsupervised: ohne Trainingsdaten; dann ist es mehr Entdecken als Lernen

Objekterkennung

Abteilung Schiele: MPI für Informatik



Personenerkennung

Abteilung Schiele: MPI für Informatik



Klassifikation (Krizhevsky et al, 2012)



rapeseed



bok choy



suit



brown bear

rapeseed
mustard
sunflower
lesser celandine
wallflower

bok choy
spinach
soy
cucumber
zucchini

suit
bow tie
academic gown
brace
oilskin

brown bear
otter
lion
ice bear
golden retriever



lotion



howler monkey



American lobster



tent

lotion
hair spray
ink bottle
nipple
nail polish

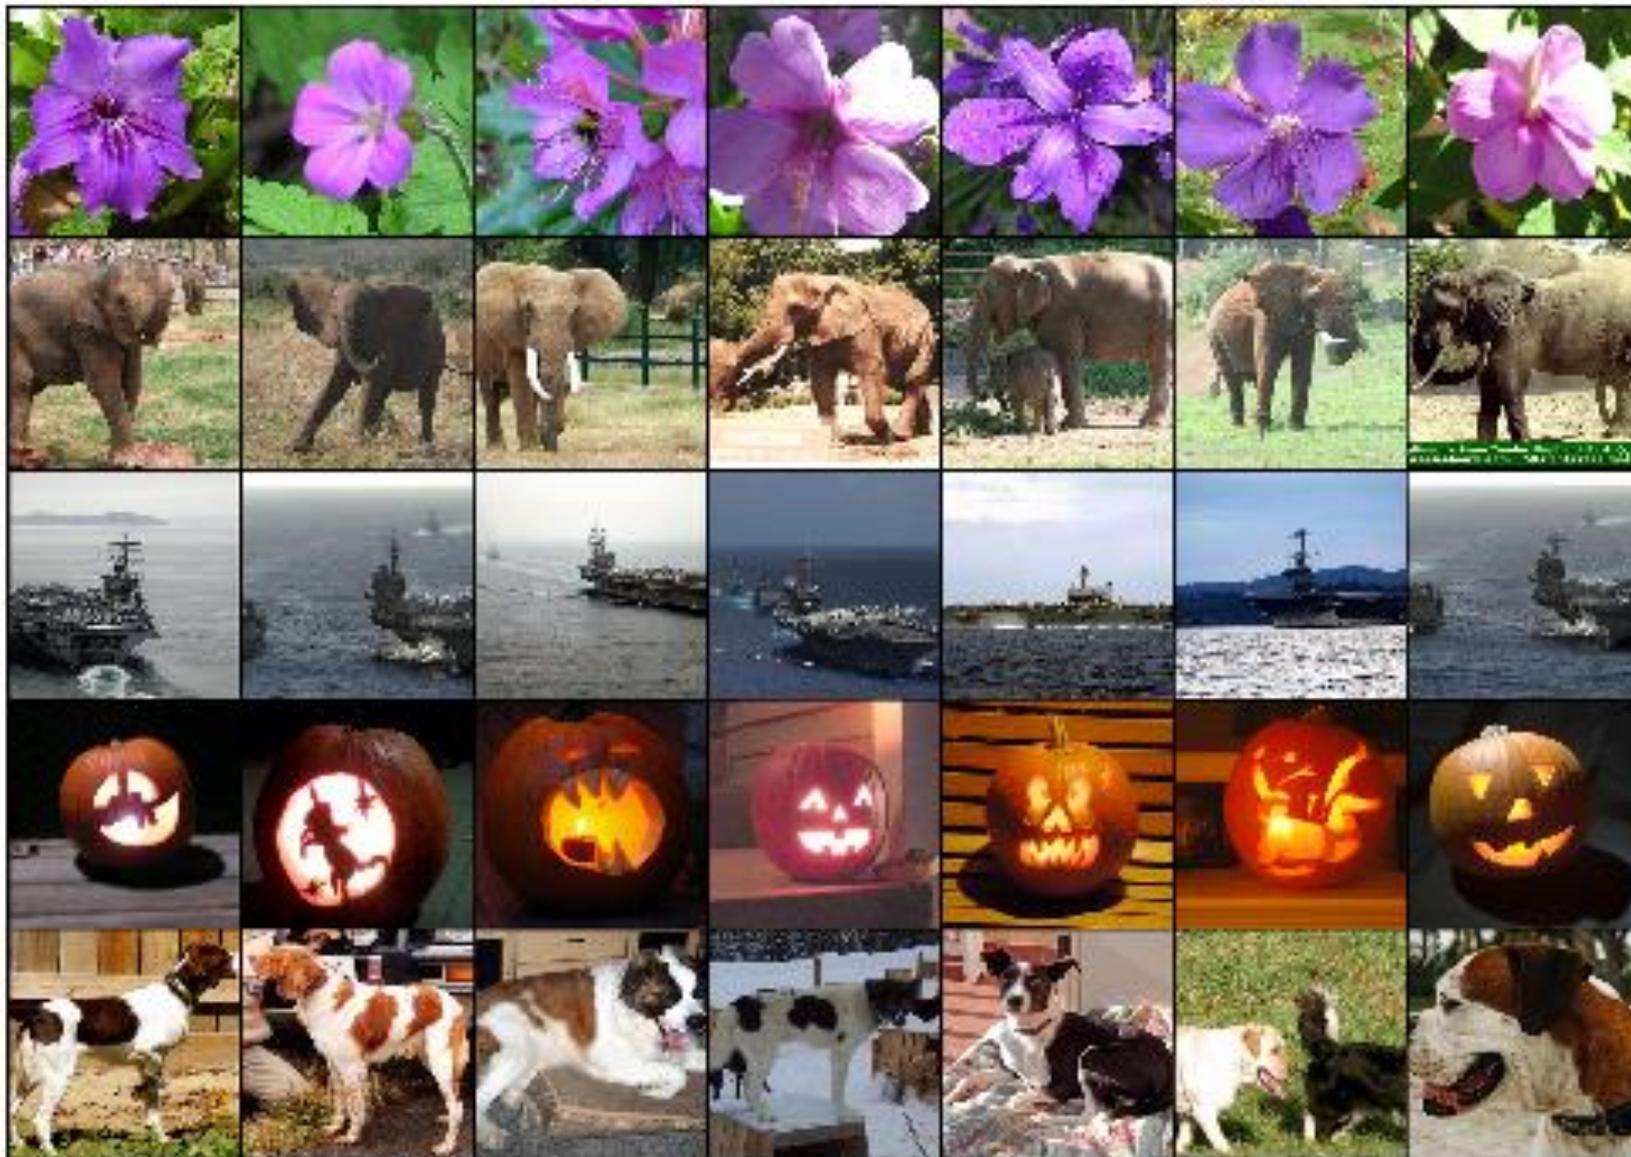
howler monkey
spider monkey
raccoon
bullfrog
indri

American lobster
tick
crayfish
king crab
barn spider

dune
tent
crutch
fishing rod
solar dish



Suche (Krizhevsky et al, 2012)



Aufgabe

- Was ist der Unterschied zwischen Supervised und Unsupervised Learning?
- Welche der folgenden Aussagen trifft zu?
 - Lernen = Erwerb neuer Fähigkeiten durch Erfahrungen
 - Lernen = Programmierung durch Beispiele
 - Lernen = Programmieren durch Angabe eines Programms

Spamerkennung

Spam = unerwünschte Nachrichten

Ham = erwünschte Nachrichten

Wir lernen einen Bayesschen Filter kennen



Bayessche Regel

(englischer Pfarrer und Mathematiker, 1701 -- 1761)

In einem Sack sind 900 Äpfel und 100 Paprika. Von den Äpfeln sind 10% rot und 90% grün. Bei den Paprika sind es jeweils 50%.

Ich entnehme eine Frucht zufällig. Sie ist rot. Was für eine Frucht ist es?

- Bayes: entscheide dich für den wahrscheinlicheren Fall und den bestimmt man so.

Bayessche Regel

In einem Sack sind 900 Äpfel und 100 Paprika.
Von den Äpfeln sind 10% rot und 90% grün. Bei
den Paprika sind es jeweils 50%.

$P(\text{Apfel} \mid \text{rot}) = \# \text{ rote Äpfel} / \# \text{ rote Früchte}$
(Prozentsatz der Äpfel unter den roten Früchten)

Spam versus Ham (Junk Mail)

- Absenderbasiert
 - email von Bekannten ist kein Spam
 - Schwarze Listen
- Inhaltsbasiert
 - Nutzer klassifiziert emails als gut und schlecht; System lernt daraus; Nutzer muss immer weniger eingreifen



Inhaltsbasierte Filter

- In der Trainingsphase lernen wir
 - Wahrscheinlichkeit von Ham und Spam
 - Jeweils Wahrscheinlichkeiten für Worte
- 70% ist Ham, 30% ist Spam

- Ham

Freund	Vorlesung	Algorithmus	Geld	Viagra	schnell
0.1	0.3	0.3	0.1	0.1	0.1

- Spam

Freund	Vorlesung	Algorithmus	Geld	Viagra	schnell
0.2	0.1	0.1	0.2	0.3	0.1

Trainingsphase

- Nutzer klassifiziert emails als Spam und Ham (damit beide Wahrscheinlichkeiten)
- Sei n die Gesamtlänge der erwünschten emails (in Worten), sei v die Anzahl der Vorkommen eines bestimmten Wortes
- Wahrscheinlichkeit des Wortes in Ham
 $= v/n$

Inhaltsbasierte Filter (Bayes Modell)

- Wahrscheinlichkeitsverteilung auf Worten

- Ham

Freund	Vorlesung	Algorithmus	Geld	Viagra	schnell
0.1	0.3	0.3	0.1	0.1	0.1

- Spam

Freund	Vorlesung	Algorithmus	Geld	Viagra	schnell
0.2	0.1	0.1	0.2	0.3	0.1

- $P(\text{Text} | \text{Ham}) = \text{Produkt der Wahrscheinlichkeiten der Worte im Text}$

Inhaltsbasierte Filter

- Ham

Freund	Vorlesung	Algorithmus	Geld	Viagra	schnell
0.1	0.3	0.3	0.1	0.1	0.1

- Spam

Freund	Vorlesung	Algorithmus	Geld	Viagra	schnell
0.2	0.1	0.1	0.2	0.3	0.1

- Viagra Geld Freund

– $P(\text{Text} \mid \text{Ham}) = 0.1 \times 0.1 \times 0.1 =$

– $P(\text{Text} \mid \text{Spam}) =$

- Bei 70% Ham und 30% Spam

Inhaltsbasierte Filter

- Ham

Freund	Vorlesung	Algorithmus	Geld	Viagra	schnell
0.1	0.3	0.3	0.1	0.1	0.1
Freund	Vorlesung	Algorithmus	Geld	Viagra	schnell
0.2	0.1	0.1	0.2	0.3	0.1

- Spam

- Vorlesung Algorithmus schnell

- Falls Ham:

- Falls Spam:

- Bei 70% Ham und 30% Spam



Inhaltsbasierte Filter

- Ham

Freund	Vorlesung	Algorithmus	Geld	Viagra	schnell
0.1	0.3	0.3	0.1	0.1	0.1

- Spam

Freund	Vorlesung	Algorithmus	Geld	Viagra	schnell
0.2	0.1	0.1	0.2	0.3	0.1

- Viagra Algorithmus schnell

- Falls Ham: $0.1 \times 0.3 \times 0.1 = 3/1000$

- Falls Spam: $0.3 \times 0.1 \times 0.1 = 3/1000$

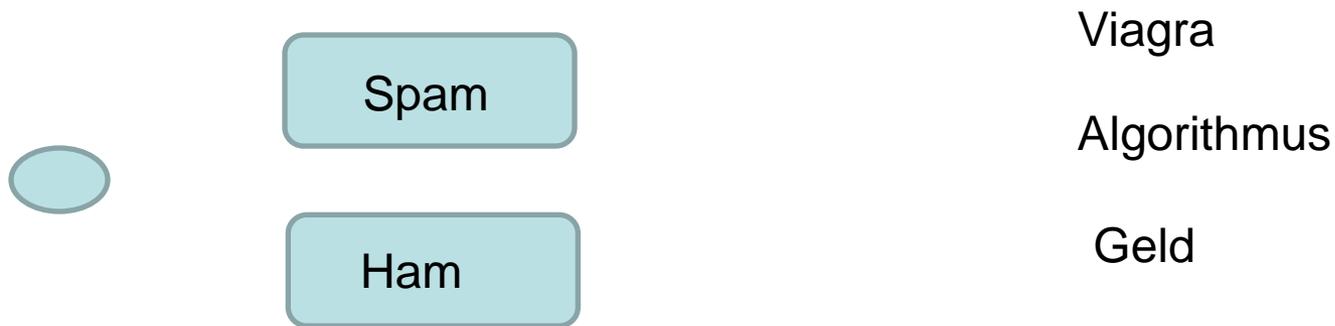
- Bei 10% Ham und 90% Spam

Nutzungsphase

- Nutzungsphase: System klassifiziert
- Verteilung wird weiter trainiert (seltene Worte)
- Nutzer kann widersprechen
- Spammer lernen auch dazu: V!agra statt Viagra

Zusammenfassung

- Wir haben Modell, wie Ereignisse (emails) erzeugt werden



- Lernen das Modell in der Trainingsphase
- Geben für jedes Ereignis die wahrscheinlichste Erklärung (Bayes)
- Klassifizierung in: Geschäftspost, Privatpost, Spam

Aufgabe

- 5% der Bevölkerung erkranken an der Krankheit X. Ein Test führt bei gesunden Patienten zu 30% zu einem positiven Ergebnis, bei kranken Patienten zu 100%. Wie hoch ist die Wahrscheinlichkeit bei einem positiven Testergebnis tatsächlich krank zu sein?
- Für das Wort Laufzeit sei die Auftretenshäufigkeit in Ham 5 mal höher als in Spam. Wie klassifizieren sie einen Text, der Algorithmus, Laufzeit und Freund enthält?

Ziffernerkennung Übersicht

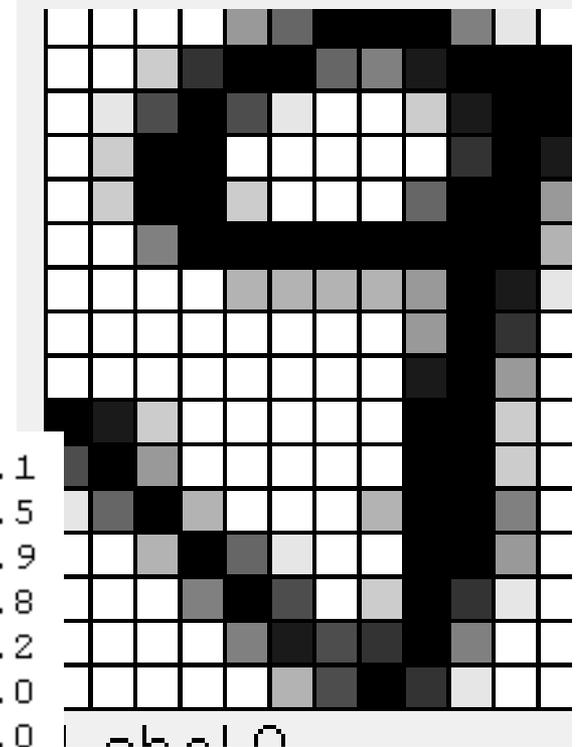
- Darstellung von Bildern in Rechnern
- Trainingsdaten: handgeschriebene Ziffern
- Supervised Learning: mit Label (die Ziffer)
- Unsupervised Learning: ohne Label

Bilder = Matrizen von Zahlen

Ziffer = 12 x 16 Matrix
von Grauwerten in [0,1]

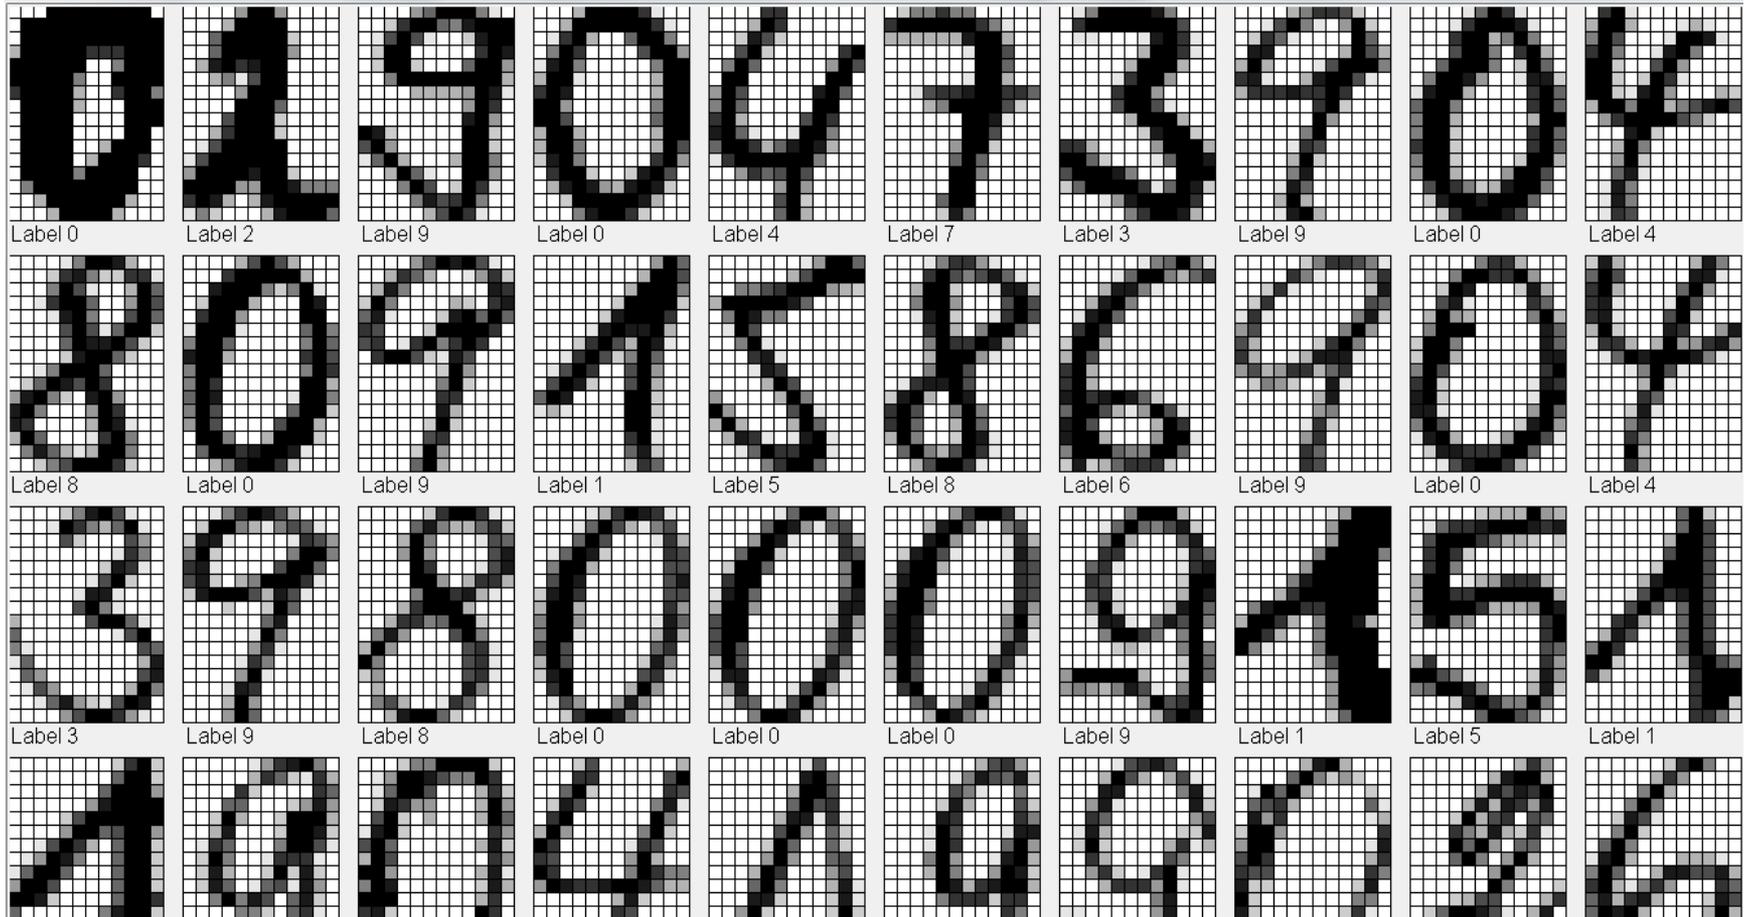
Vektor von Grauwerten
der Lande 192

0.0	0.0	0.0	0.2	0.3	0.4	0.8	1.0	1.0	0.7	0.3	0.1
0.0	0.5	0.8	0.9	1.0	1.0	1.0	1.0	1.0	1.0	1.0	0.5
0.3	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0	0.9
0.3	1.0	1.0	1.0	1.0	1.0	0.8	1.0	1.0	1.0	1.0	0.8
0.3	1.0	1.0	1.0	1.0	0.8	0.1	0.9	1.0	1.0	0.8	0.2
0.0	0.7	1.0	1.0	1.0	0.8	0.8	1.0	1.0	1.0	0.4	0.0
0.0	0.2	1.0	1.0	1.0	1.0	1.0	1.0	0.9	0.3	0.0	0.0
0.0	0.1	0.7	1.0	1.0	1.0	1.0	0.8	0.1	0.0	0.0	0.0
0.0	0.6	1.0	1.0	1.0	1.0	0.9	0.1	0.0	0.0	0.0	0.0
0.6	1.0	1.0	1.0	1.0	1.0	1.0	0.3	0.0	0.0	0.0	0.0
0.8	1.0	1.0	0.5	0.1	0.7	1.0	0.8	0.2	0.0	0.0	0.0
0.5	1.0	1.0	0.3	0.0	0.0	0.9	1.0	0.9	0.1	0.0	0.0
0.4	1.0	1.0	0.3	0.0	0.0	0.5	1.0	1.0	0.5	0.0	0.0
0.0	0.4	1.0	1.0	0.5	0.3	0.5	1.0	1.0	1.0	0.2	0.0
0.0	0.0	0.5	1.0	1.0	1.0	1.0	1.0	1.0	0.8	0.1	0.0
0.0	0.0	0.0	0.2	0.5	0.7	1.0	1.0	0.9	0.3	0.0	0.0



Ihr Gehirn sieht
Ziffern, ihr Auge und
Computer sehen nur
eine Matrix von
Grauwerten

Trainingsdaten



Ziemlich gutmütig

Grundidee

- Zwei Bilder repräsentieren die gleiche Ziffer, wenn die Bilder sich ähnlich sind.
- Ähnlich = ähnliche Grauwertverteilung

Ähnlichkeit von Vektoren

- Zwei Vektoren x und y sind ähnlich,
 - wenn $d = \|x - y\|$ klein ist
 - Wenn der aufgespannte Winkel klein ist

Länge eines Vektors $x = (x_1, \dots, x_n)$

$$\|x\| = \sqrt{x_1^2 + x_2^2 + \dots + x_n^2}$$

Winkel zwischen x und y

$$\cos \alpha = \frac{x \cdot y}{\|x\| \cdot \|y\|}$$

Verfahren: Nearest Neighbor

Um die Bedeutung des Bildes p zu finden, finde das Trainingsbild x mit $\text{dist}(p,x)$ minimal (durch lineare Suche über alle Trainingsdaten)

Gib das Label von x aus

- Erkennungsrate 0.934
- Majority of 3 nearest neighbors 0.945
- Majority of 9 nearest neighbors 0.920

- Mit cos-Distanz 0.940
- Majority of 3 nearest neighbors 0.920

Detaillierte Ergebnisse

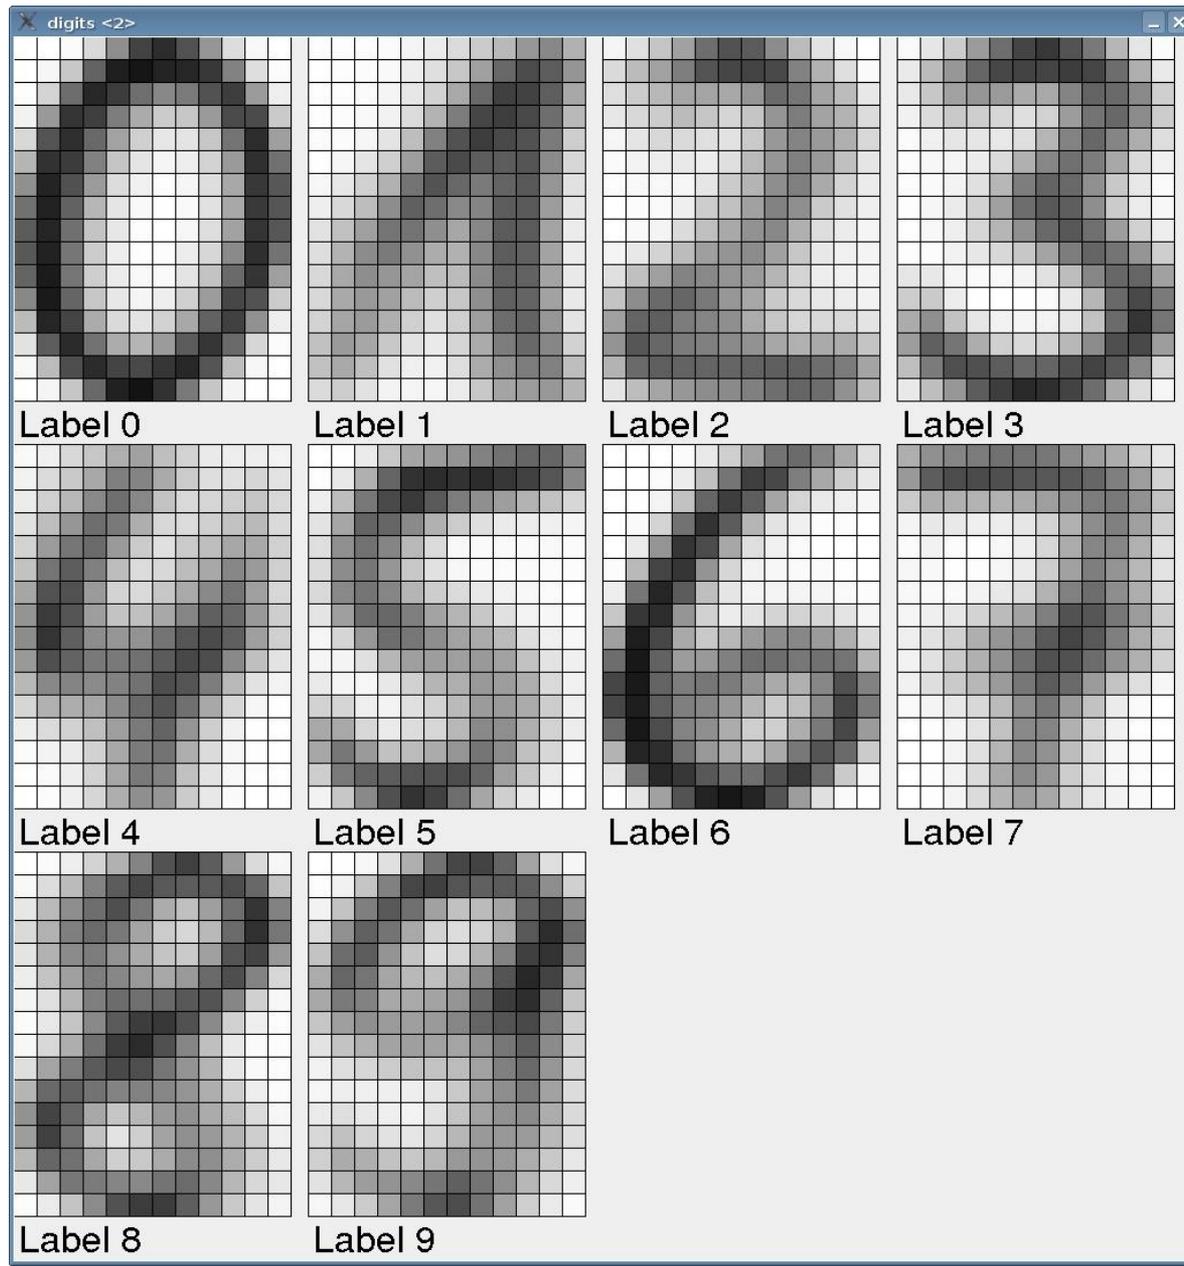
digit = 0 accuracy = 1.0
digit = 1 accuracy = 0.90
digit = 2 accuracy = 0.92
digit = 3 accuracy = 1.0
digit = 4 accuracy = 0.95
digit = 5 accuracy = 0.85
digit = 6 accuracy = 0.84
digit = 7 accuracy = 1.0
digit = 8 accuracy = 0.7
digit = 9 accuracy = 0.94

Klassifizierung ist recht gut, aber sie dauert sehr **lang**, da jedes Mal ALLE Trainingsdaten angeschaut werden

Klassen → Klassenzentren

- Vorbereitung: Berechne für jede Klasse (Ziffer) das Klassenzentrum durch Durchschnitts. siehe nächste Folie
- Suche: finde das nächstgelegene Zentrum (10 Vergleiche)
- Erkennungsrate: 0.854
- Mit cos-distance 0.894
- Sehr effizient, aber schlechter

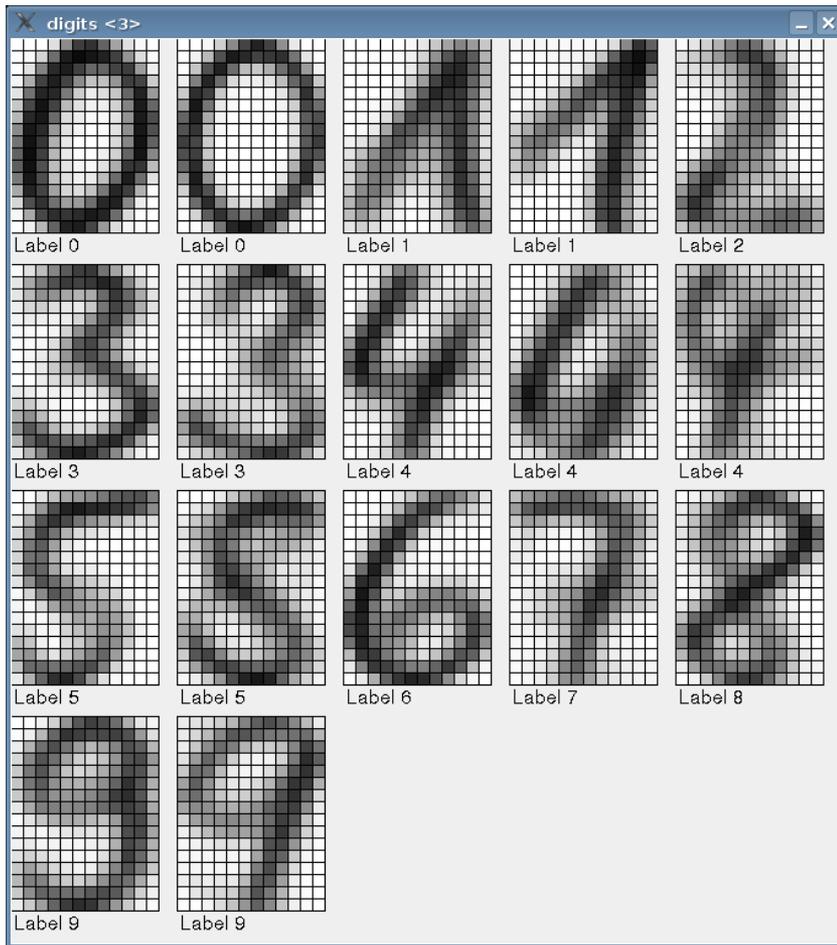
Die Klassenzentren



Unsupervised Lernen

- Vorbereiten der Trainingsdaten ist mühsam
- Können wir Klassen entdecken, ohne das uns Klassenlabels gesagt werden?
- Automatische Klassifizierung durch k-means Algorithmus.
- Danach Vergleich mit den Klassenzentren
- $k=10$, Rate 0.683
- $k=17$, 0.733
- with cos-distance,
- $k=10$, 0.728
- $k=17$, 0.783
- $k=30$, 0.864

K-means Algorithmus



- Automatische Klassifizierung in 17 Klassen
- Danach (!!!) Zuweisung eines Labels per Hand und Wegwerfen von schlechten Zentren
- Identifiziert die zwei Schreibweisen der Neun und der Eins

k-means Algorithmus

Teilt n Punkte in k Cluster (Haufen) ein.

1. Starte mit k beliebigen (zufälligen) Zentren
2. Weise jeden Punkt dem nächstgelegenen Zentrum zu und bilde so k Cluster
3. Berechne für jeden Cluster seinen Schwerpunkt; das sind die neuen Zentren
4. Gehe nach 2.