Vorlesungsplan

- 17.10. Einleitung
- 24.10. Ein- und Ausgabe
- 31.10. Reformationstag, Einfache Regeln
- 7.11. Naïve Bayes, Entscheidungsbäume
- 14.11. Entscheidungsregeln, Assoziationsregeln
- **21.11. Lineare Modelle, Instanzbasiertes Lernen**
- 28.11. Clustering I
- 5.12. Clustering II
- 12.12. Evaluation I
- 19.12. Evaluation II
- 9.1. Entscheidungsbäume, Klassifikationsregeln
- 16.1. Lineare Modelle, Numerische Vorhersage
- 23.1. Clustering
- 30.1. Attribut-Selektion, Diskretisierung, Transformationen
- 6.2. Kombination von Modellen, Lernen von nicht-klassifizierten Beispielen

Lineare Modelle

- Sind auf nummerischen Attributen definiert
- Standard Technik für nummerische Vorhersage: lineare Regression
  - Ergebnis ist Linearkombination der Attribute

$$x = w_0 + w_1 a_1 + w_2 a_2 + \ldots + w_k a_k$$

- Gewichte berechnet aus den Trainingsdaten
- Vorhergesagter Wert für die erste Trainings-Instanz $\mathbf{a}^{(1)}$ (Index oben bezeichnet i-te Instanz)

$$w_0 a_0^{(1)} + w_1 a_1^{(1)} + w_2 a_2^{(1)} + \ldots + w_k a_k^{(1)} = \sum_{j=0}^{k} w_j a_j^{(1)}$$

Methode der kleinsten Quadrate

- Wähle *k* +1 Koeffizienten um das Quadrat des Fehlers auf den Trainingdaten zu minimieren
- Quadrierter Fehler: $\sum_{i=1}^{n} \left(x^{(i)} - \sum_{j=0}^{k} w_j a_j^{(i)} \right)^2$
- Berechne Koeffizienten mittels standard Matrix Operationen
- Sinnvoll wenn mehr Instanzen als Attribute (n>k)
- Minimieren des *absoluten Fehlers* ist schwieriger

Klassifikation

- Jede Regressionstechnik kann zur Klassifikation genutzt werden
  - Training: führe Regression für jede Klasse c durch indem für die Trainingsinstanzen, die zu c gehören, das Ergebnis 1 und für den Rest auf 0 gesetzt wird
  - Vorhersage: berechne Regressionswert für alle Klassen, wähle Klasse nach größtem Ergebnis aus (Mitgliedschaftswert)
- Für lineare Regression heißt dies *multi-response linear regression*

Klassifikation durch paarweise Regression

- Zweite Möglichkeit Regression zur Klassifikation zu nutzen:
  - Ein Regressionsfunktion für jedes Klassenpaar unter Verwendung nur der Instanzen dieser zwei Klassen
  - Ergebnis für die eine Klasse ist +1 für die andere –1
- Vorhersage durch Abstimmung
  - Klasse mit den meisten Stimmen wird ausgewählt
  - Alternative: “weiss nicht” falls kein Übereinstimmung

Logistische Regression

- Problem: Lineare Regression für mehre Klassen liefert Mitgliedschaftswerte außerhalb [0,1], daher keine Wahrscheinlichkeiten
- *Logistische* Regression: Alternative zu linearer Regression
  - Schätzt Klassenwahrscheinlichkeiten direkt
    - mittels *maximum likelihood* Methode
  - Nutzt lineares Modell:

$$\log\left(\frac{P}{1-P}\right) = w_0 a_0 + w_1 a_1 + w_2 a_2 + \ldots + w_k a_k$$

Klassenwahrscheinlichkeit

Lineare Klassifikation mit Perzeptronen

- Perzeptron lernt Hyperebene um zwei Klassen zu trennen

$$w_0 a_0 + w_1 a_1 + \ldots + w_k a_k = 0$$

```
Set all weights to zero
Until all instances in the training data are classified correctly
    For each instance I in the training data
      If I is classified incorrectly by the perzeptron
        If I belongs to the first class then add it to the weight vector
        Else subtract it from the weight vector
```

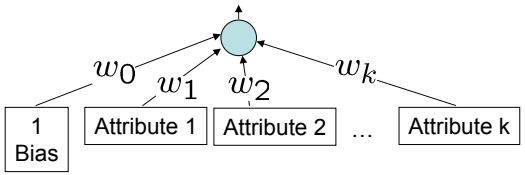

Diskussion linearer Modelle

- Nicht sinnvoll wenn Daten starke nicht-lineare Abhängigkeiten enthalten
- Aber: können als Bausteine für komplexere Schemata dienen (z.B. Regressionsbäume)
- Beispiel: Multi-response lineare Regression definiert eine *Hyperebene* für jedes Klassenpaar:

$$(w_0^{(1)} - w_0^{(2)})a_0 + (w_1^{(1)} - w_1^{(2)})a_1 + (w_2^{(1)} - w_2^{(2)})a_2 + \ldots + (w_k^{(1)} - w_k^{(2)})a_k > 0$$

Instanz-basierte Repräsentation

- Einfachste Form des Lernen: *Auswendiglernen*
  - Trainingsinstanzen werden nach der Instanz durchsucht, die einer neuen Instanz am nächsten kommt
  - Die Instanzen selbst repräsentieren das Wissen
  - Auch *instanz-basiertes* Lernen genannt
- Distanz/Ähnlichkeitsfunktion definiert was gelernt heißt
- Instanz-basiertes Lernen ist *faul*
- Methoden:
  - *nächste Nachbar*
  - *k-nächste Nachbarn*
  - …

Die Distanz Funktion

- Einfachster Fall: ein nummerisches Attribut
  - Distanz ist die Differenz zwischen zwei Attributwerten (oder einer Funktion davon)
- Mehrere nummerische Attribute: häufig wird Euklidische Distanz genutzt und Attribute sind normalisiert
- Nominales Attribut: Distanz ist 1 falls Werte verschieden sind, 0 sonst
- Sind alle Attribute gleichwichtig?
  - Gewichtung der Attribute kann notwendig sein

Normalisierung

- Unterschiedliche Attribute werden auf verschiedenen Skalen gemessen ⇒ Normalisierung
  - Min-Max Normalisierung $$a_i = \frac{v_i - \min v_i}{\max v_i - \min v_i}$$

    v_i: the actual value of attribute i
  - Zero Mean, Varianz 1 $$a_i = \frac{v_i - mean(v_i)}{sdev(v_i)}$$
- Oft angewandte Regel für fehlende Werte: Annahme, diese sind maximal weit weg, bezüglich normalisierter Attribute

Diskussion von 1-NN

- Oft sehr genau
- … aber sehr langsam:
  - einfache Version vergleicht gegen alle Trainingsdaten für eine Vorhersage
- Annahme, daß alle Attribute gleichwichtig sind
  - Abhilfe: Attributauswahl oder Gewichte
- Möglichkeiten gegen verrauschte Instanzen :
  - Mehrheit der k nächsten Nachbarn
  - Löschen von verrauschten Instanzen aus den Trainingsdaten (schwierig)
- Statistiker nutzen *k*-NN seit den frühen 1950zigern
  - Falls $n \to \infty$ und $k/n \to 0$, Fehler wird minimal