Kapitel VI + VII

Modellierung/ Data-Mining-Verfahren

Kapitel VI + VII: Data-Mining Verfahren

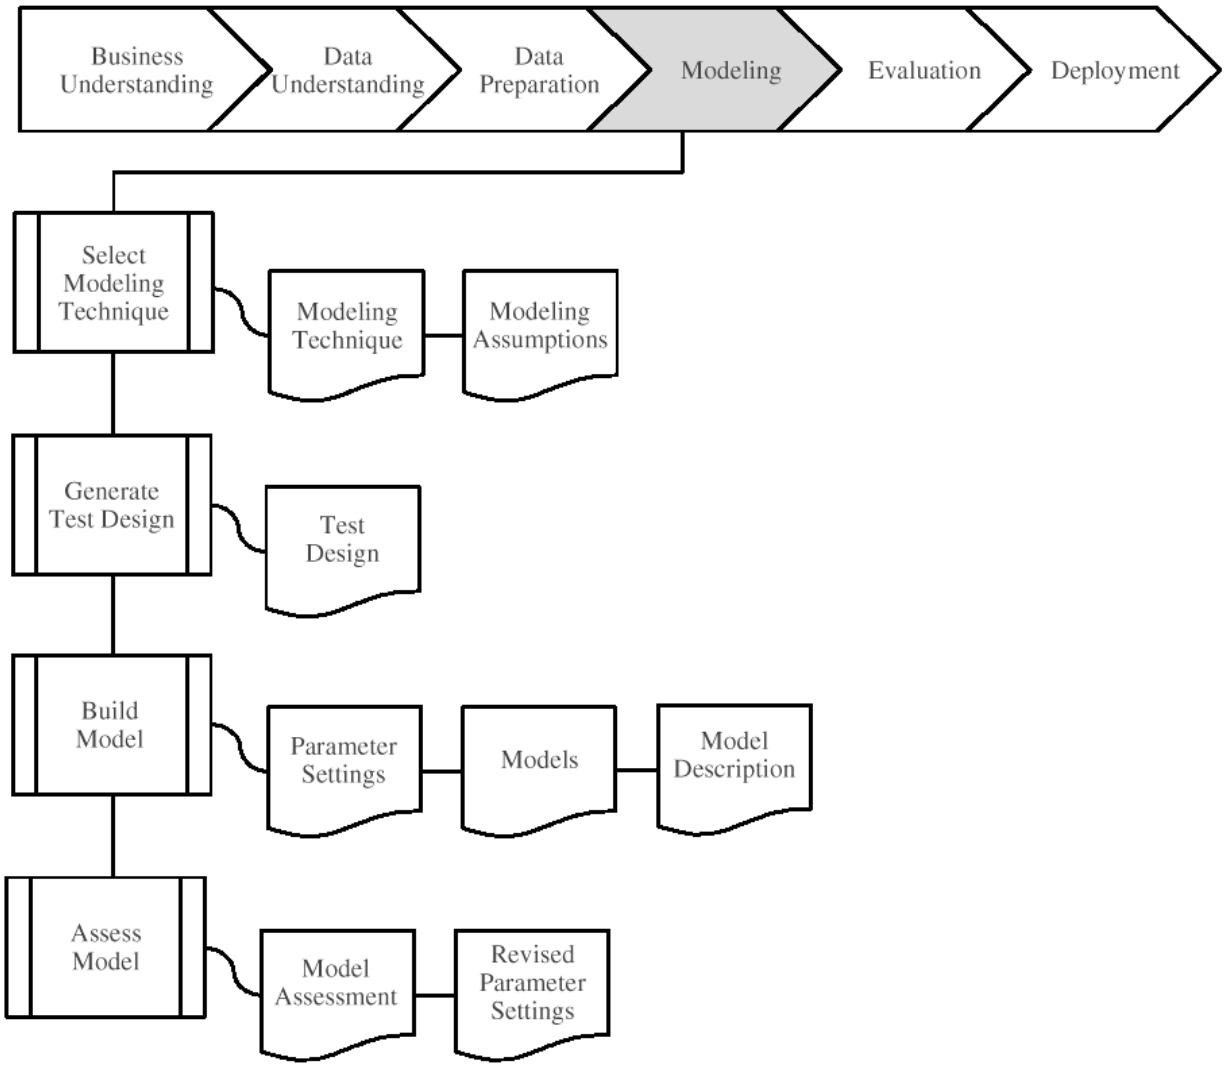

Chapter VI

Supervised Learning Algorithms

Chapter VI.1

Decision Trees

VI.1 Konstruktion von Entscheidungsbäumen
(Langley 1996, Quinlan 1993)

VI.1.1 Grundlagen

- *Entscheidungsbäume* sind eine spezielle Form von *Konzepthierarchien*
- *Grundidee*:
  - aus gegebenen *Trainingsbeispielen* wird Entscheidungsbaum aufgebaut
  - Entscheidungsbaum liefert *intensionale Beschreibung* der *vorgegebenen* Klassen
  - Entscheidungsbaum ordnet *neue* Beispiele mit gewisser *Fehlerrate* einer der vorgegebenen Klassen zu

Generelle *Voraussetzungen*:

- Beispiele werden in Form von *Attribut-Wert-Paaren* beschrieben
  - Attribut hat *Name* und *Wertebereich*
  - Wertebereich ist nominal, diskret oder kontinuierlich
  - jedes Beispiel wird durch *dieselben* Attribute beschrieben (vgl. relationale Datenbanken)

- Menge von *Klassen* (Konzepten) ist *vordefiniert*; i.a. ist die Anzahl der Klassen sehr viel kleiner als die Zahl der Trainingsbeispiele

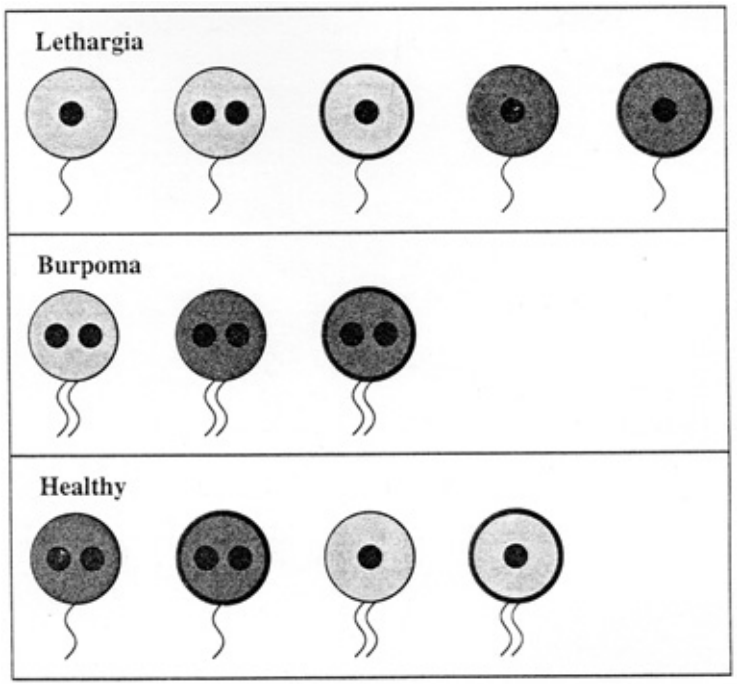

Abbildung VI.1-1: Training instances from a cell domain involving four attributes and three distinct classes. (Langley 1996)

Attributes:

number of nuclei	(values: 1,2)
number of tails	(values: 1,2)
color	(values: light, dark)
wall	(values: thin, thick)

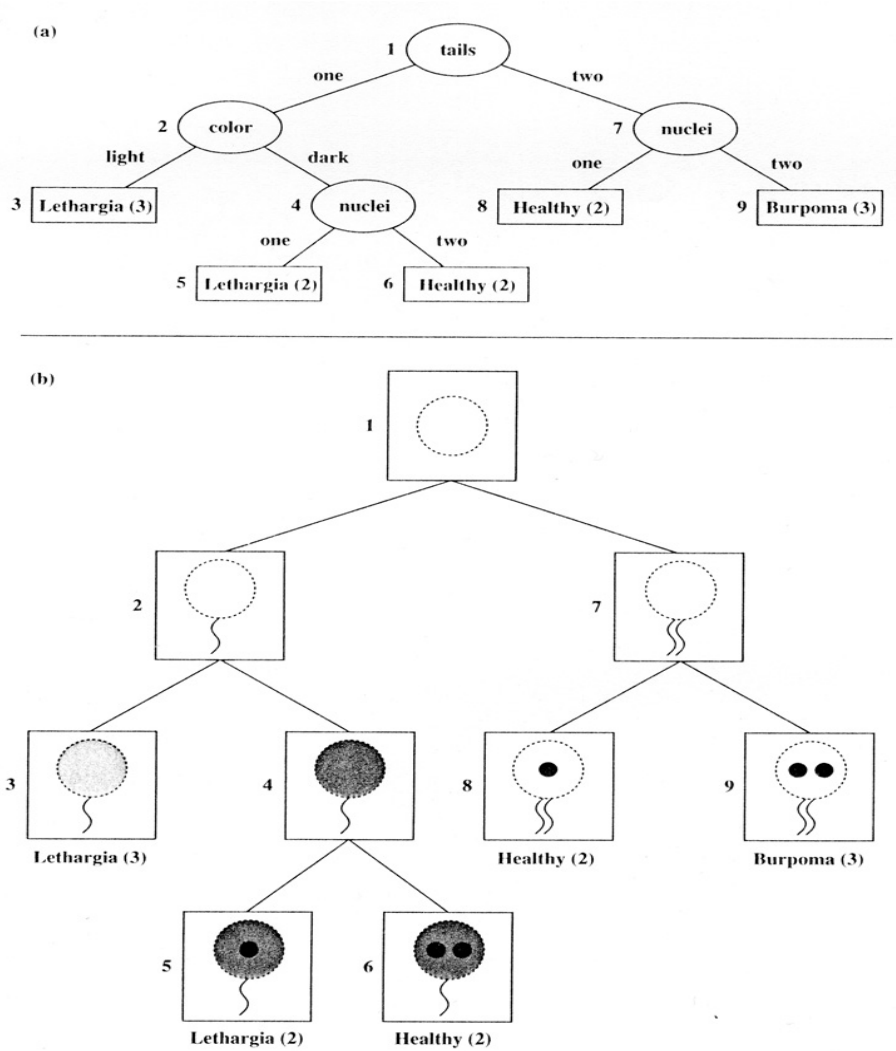

Abbildung VI.1-2: A decision tree generated by the DDT algorithm for the training instances from Abbildung VI.1-1. Each terminal node specifies an associated class name and the number of training cases covered. Numbers next to the notes indicate the order in which the algorithm generated them. The notation (a), which associates attributes with nodes and values with links, is equivalent to (b), which shows the instances that each node covers. (Langley 1996)

° Von jedem Trainingsbeispiel ist (idealerweise) die *Klassenzugehörigkeit bekannt*
- überwachtes Lernen (*supervised learning*)
- ein Attribut spezifiziert jeweils die Klassenzugehörigkeit (vgl. auch Holländer- Klassifizierung)

° Klassen müssen durch Entscheidungsbäume oder Produktionsregeln beschreibbar sein
- typischerweise Beschreibungen der *Form*

$$[(\text{att}_{i_1} = \text{value}_{i_1}) \wedge \ldots \wedge (\text{att}_{i_n} = \text{value}_{i_n})]$$

Beispiel: Klasse Healthy:

[(number_of_tails = 2) $\wedge$ (number_of_nuclei = 1)] $\vee$
[(number_of_tails = 1) $\wedge$ (color = dark) $\wedge$
(number_of_nuclei = 2)]

Struktur eines *univariaten Entscheidungsbaums*:

- Blattknoten werden mit jeweils *einer Klasse* benannt, alle anderen Knoten mit jeweils einem Test auf *ein einziges Attribut*
- wenn das Attribut eines Knotens *k* verschiedene Werte hat (bzw. in k Wertebereiche aufgeteilt wird), dann hat der Knoten *k* Sohnknoten
- Beispielmenge wird an dem Knoten in *k* disjunkte Teilmengen partitioniert in Abhängigkeit vom jeweiligen Wert des Attributs
- Die *Extension* eines Knotens ist immer eine Obermenge der Extension aller Sohnknoten

- verbinde jeden Knoten mit all seinen Sohnknoten und beschrifte die *Kanten* mit ihren zugehörigen Attributwerten

- *neue Fälle* durchlaufen für ihre Klassifikation den Entscheidungsbaum von der Wurzel ausgehend bis zu einem Blattknoten

Graphisch:

- m Attribute a_1, a_2, ... a_m
- Wertebereich
  - von Attribut a_i: $\{a_{i_1},...,a_{i_{k_i}}\}$
  - von Attribut a_l: $\{a_{l_1},...,a_{l_{k_l}}\}$

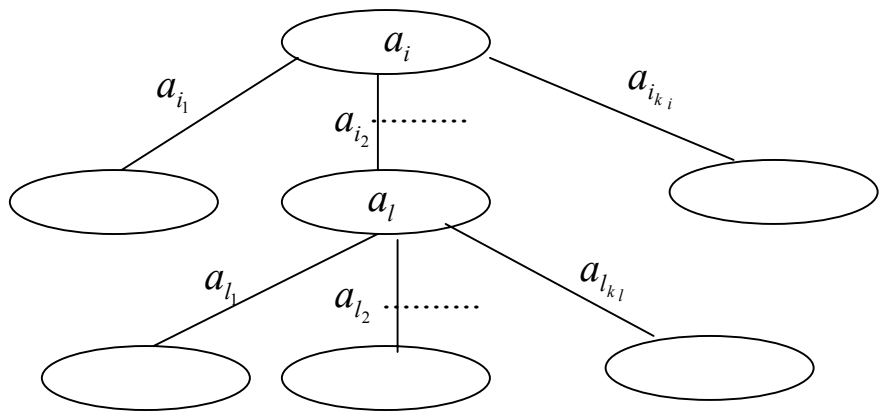

Wie man in Holland Leute erkennt (ohne Gewähr) ...

	Schuhe	Lieblings-Käse	Wohn-wagen	Holländisch
1	Unbek.	Gouda	Ja	+
2	Unbek.	Camembert	Ja	-
3	Klompen	Gouda	Ja	+
4	Normal	Gouda	Nein	-
5	Klompen	Camembert	Ja	+
6	Unbek.	Gouda	Nein	+
7	Normal	Gouda	Ja	-
8	Klompen	Gouda	Nein	+
9	Unbek.	Camembert	Nein	-
10	Normal	Camembert	Ja	-

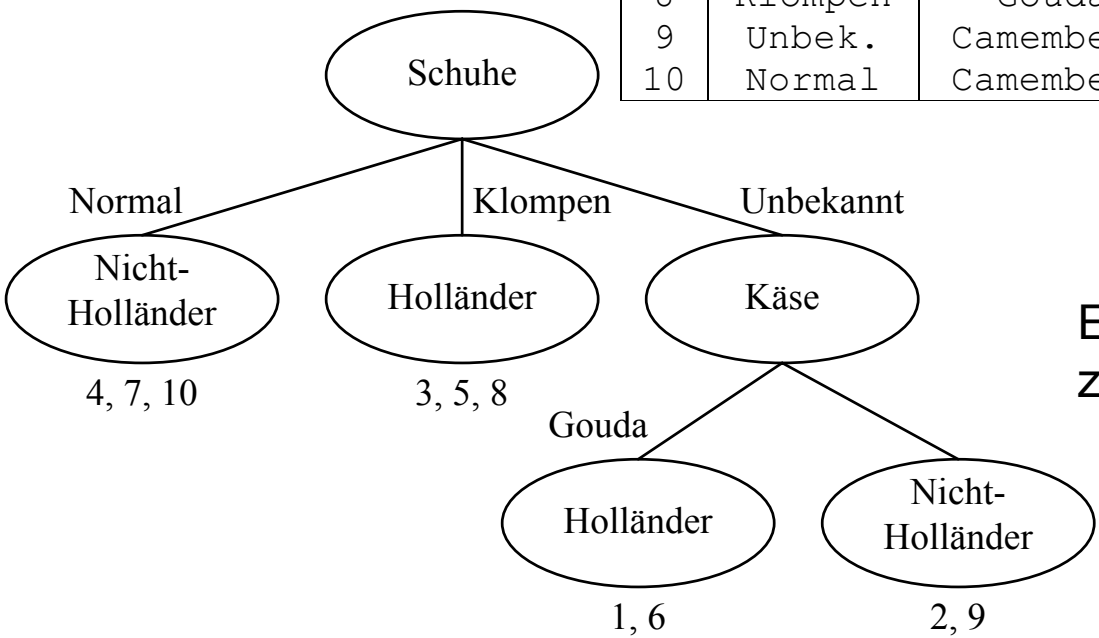

Ein Entscheidungsbaum zur Klassifikation

Grafische Veranschaulichung der Klassifikationsaufgabe:

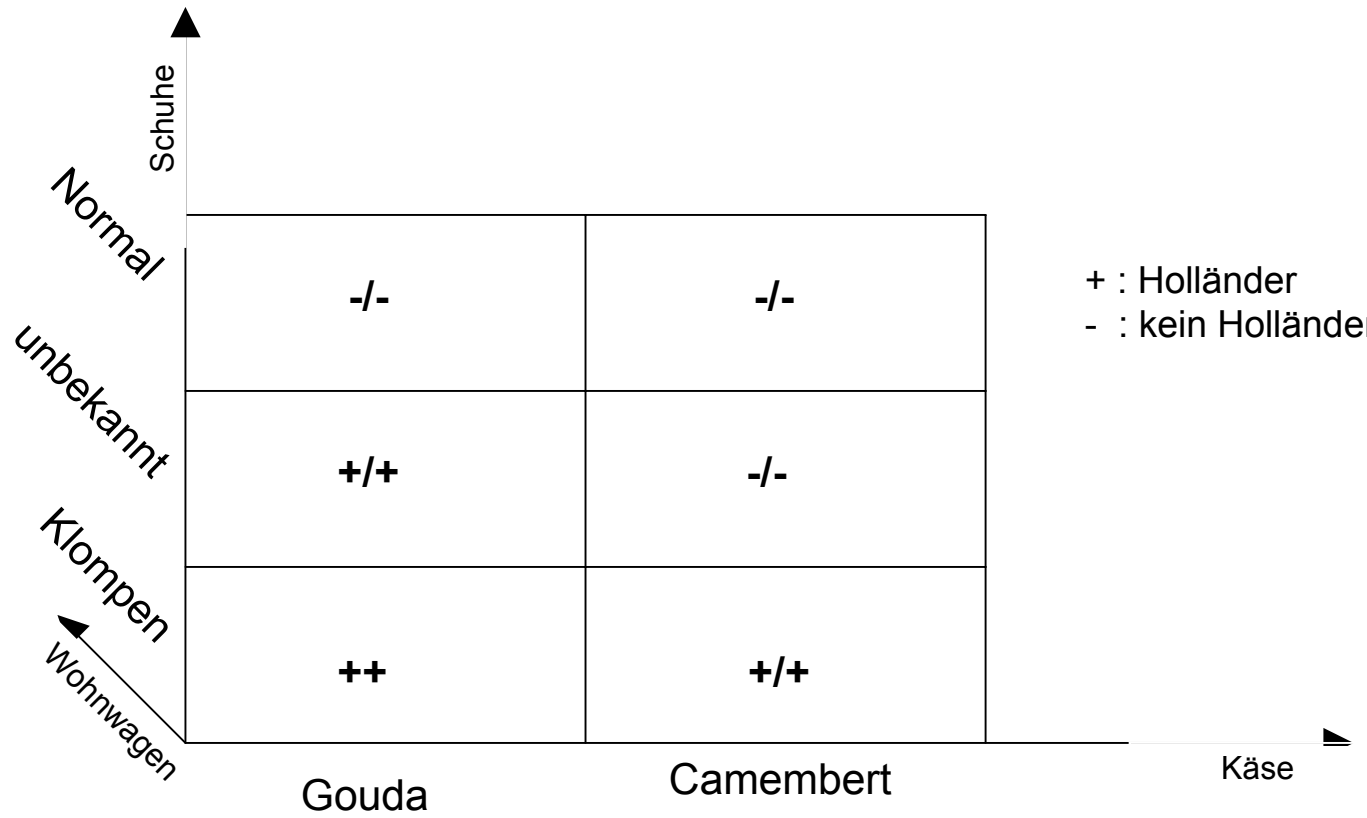

- Beispielalgorithmus für Aufbau eines univariaten Entscheidungsbaums:

DDT - Algorithmus: Divisive Induction of Univariate Decision Trees

- DDT ist *nicht-inkrementell:*
  - alle Trainingsbeispiele müssen verfügbar sein

- DDT ist *Greedy*-Algorithmus (greedy=gierig):
  - lokal optimale Entscheidungen werden getroffen
  - getroffene Entscheidungen können nicht mehr zurückgenommen werden

DDT Algorithm: Divisive Induction of Univariate Decision Trees

Inputs: The current node N of the decision tree.
A set of classified training instances ISET.
A set of symbolic attributes and their values ASET.

Output: A univariate decision tree.

Top-level call: DDT(root, ASET, ISET).

Procedure DDT(N, ASET, ISET)

If the training set ISET is empty,

Then label terminal node N as DEFAULT.

Else IF all instances ISET are equal with respect to all attributes in ASET // neuer Blattknoten

// this is especially the case if ASET is empty // gefunden

Then label terminal node N with the *class name*.

Else *for each attribute* A in ASET,

Evaluate A according to its ability to // wähle „bestes“

discriminate the classes in ISET. // Attribut B

Select attribute B with the *best evaluation score*. //

For each value V of B,

Create a new child C of node N. // expandiere

Label the edge from N to C with V. // aktuellen

Let JSET be the ISET instances having value V on B. // Knoten

Let KSET be ASET \ {B}.

DDT(C, KSET, JSET).

Beispiel "Spielen im Freien":

- 4 Attribute
- 2 Klassen: Play
  Don‘t Play

Outlook	Temp (F)	Humidity (%)	Windy?	Class
sunny	75	70	true	Play
sunny	80	90	true	Dont´t Play
sunny	85	85	false	Dont´t Play
sunny	72	95	false	Dont´t Play
sunny	69	70	false	Play
overcast	72	90	true	Play
overcast	83	78	false	Play
overcast	64	65	true	Play
overcast	81	75	false	Play
rain	71	80	true	Dont´t Play
rain	65	70	true	Dont´t Play
rain	75	80	false	Play
rain	68	80	false	Play
rain	70	96	false	Play

Abbildung VI.1-3: A small training set (Quinlan 1993)

Partition of cases:

outlook = sunny:

humidity ≤ 75:

Outlook	Temp (°F)	Humidity (%)	Windy?	Decision
sunny	75	70	true	Play
sunny	69	70	false	Play

humidity > 75:

Outlook	Temp (°F)	Humidity (%)	Windy?	Decision
sunny	80	90	true	Don't Play
sunny	85	85	false	Don't Play
sunny	72	95	false	Don't Play

outlook = overcast:

Outlook	Temp (°F)	Humidity (%)	Windy?	Decision
overcast	72	90	true	Play
overcast	83	78	false	Play
overcast	64	65	true	Play
overcast	81	75	false	Play

outlook = rain:

windy = true:

Outlook	Temp (°F)	Humidity (%)	Windy?	Decision
rain	71	80	true	Don't Play
rain	65	70	true	Don't Play

windy = false:

Outlook	Temp (°F)	Humidity (%)	Windy?	Decision
rain	75	80	false	Play
rain	68	80	false	Play
rain	70	96	false	Play

Corresponding decision tree:

```
outlook = sunny:
    humidity ≤ 75: Play
    humidity > 75: Don't Play
outlook = overcast: Play
outlook = rain:
    windy = true: Don't Play
    windy = false: Play
```

Abbildung VI.1-4: Final partition of cases and corresponding decision tree

(Quinlan 1993)

Graphische Darstellung des Entscheidungsbaumes zum Beispiel:

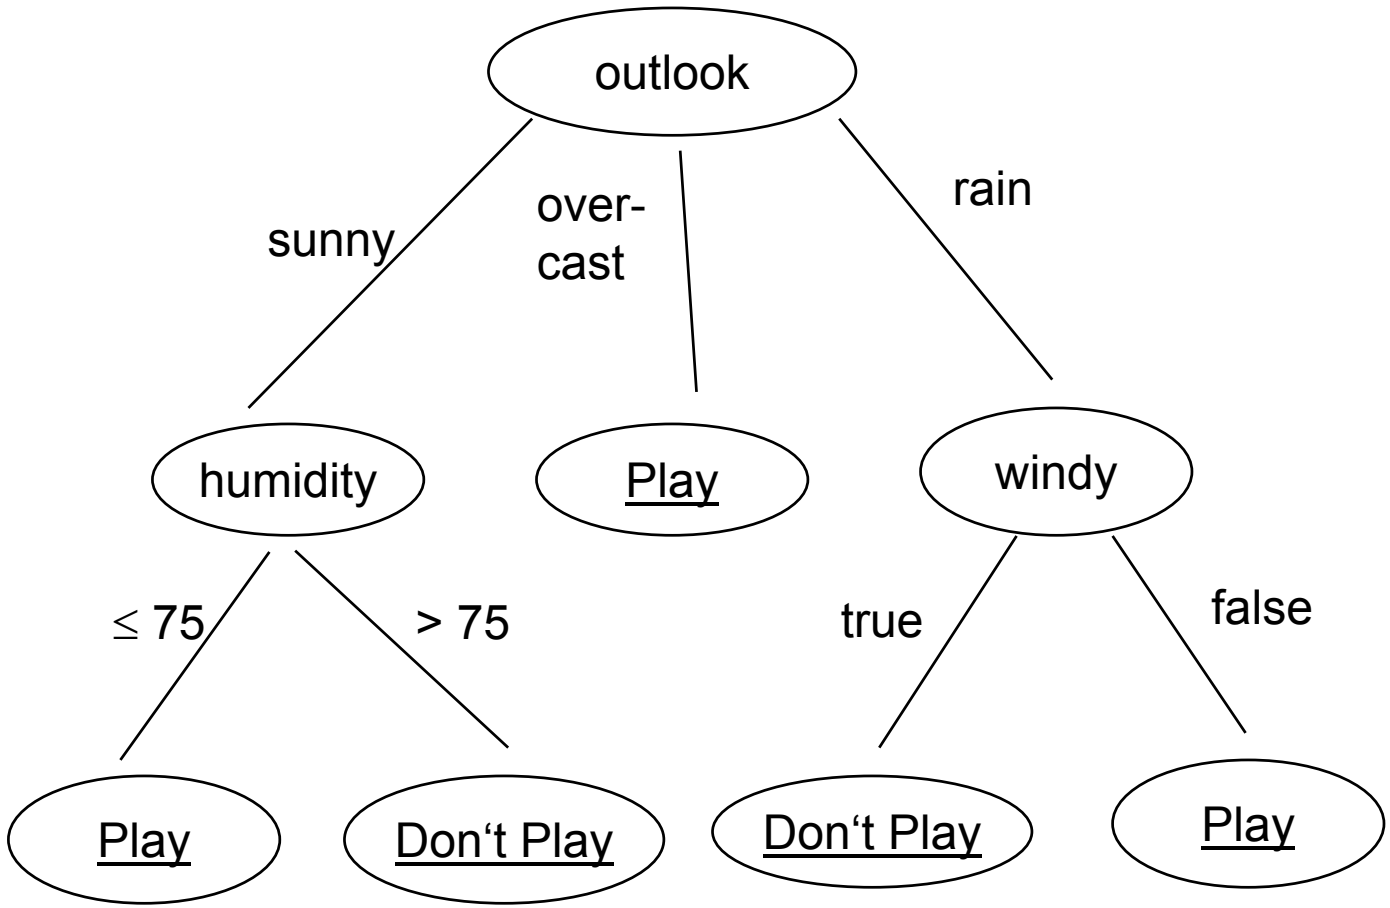

VI.1.2 C4.5 - Algorithmus (Quinlan 1993)

- weitverbreiteter Algorithmus zum Aufbau von Entscheidungsbäumen (oder entsprechenden Produktionsregeln)

- Spezielle *Variante* des DDT-Algorithmus:
  - ° Verwendung einer speziellen *Bewertungsfunktion* für Auswahl des besten Attributs: *gain ratio*
  - ° beinhaltet zusätzlich Verfahren zur nachträglichen *Vereinfachung* des erzeugten Entscheidungsbaums: *pruning*
  - ° aus Entscheidungsbaum können entsprechende *Produktionsregeln* erzeugt werden
    - $\Rightarrow$ alternative lesbarere Darstellung
  - ° *Windowing* - Technik für Handhabung einer großen Anzahl von Beispielen

a) Bewertungsfunktion für Attributauswahl

- für gegebene Menge von Trainingsbeispielen ist Anzahl der möglichen Entscheidungsbäume i.a. *sehr groß*
- Daher ist Generierung *aller* Entscheidungsbäume und dann Auswahl des Besten (exhaustive search) *nicht möglich*
- Daher wird in jedem Expansionsschritt das *vielversprechendste* Attribut ausgewählt (Greedy Algorithmus): verwende das Attribut, das *am meisten Information* liefert (im Sinne der Informationstheorie)
- C4.5 verwendet *gain ratio* als Kriterium. Es ist eine Abwandelung des im folgenden beschriebenen *gain criterion.*

gain criterion

- Bezeichnungen: S: Gesamtbeispielmenge

T: Menge der Trainingsbeispiele ($T \subset S$)

$T_1, T_2, ..., T_n$: Partition von T

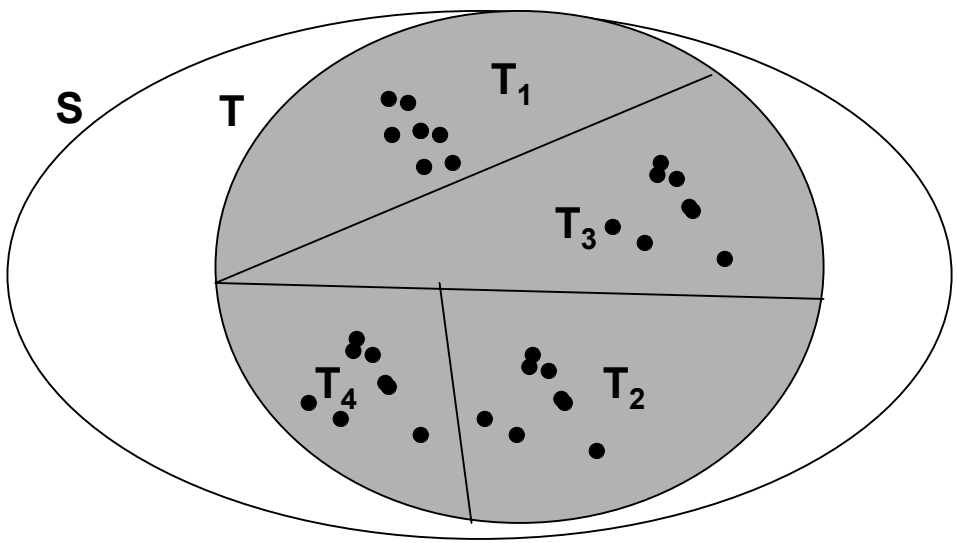

- Informationsgehalt einer Botschaft b_i:

  hat b_i die Wahrscheinlichkeit p_i ,

  so ist der Informationsgehalt von $b_i \equiv -\log_2 (p_i)$ bits

Beispiel: 8 gleichwahrscheinliche Botschaften b_1, ... ,b_8 :

jedes b_i hat den Informationsgehalt

$$-\log_2(\frac{1}{8}) \text{ bits} = 3 \text{ bits}$$

- Botschaft, die mitteilt, dass beliebig ausgewähltes Beispiel aus Menge T in Klasse c_i liegt, hat den Informationsgehalt

$$-\log_2\left(\frac{|C_i \cap T|}{|T|}\right) \text{ bits}$$

- Erwartungswert für den Informationsgehalt dieser Botschaften (bei k Klassen $C_1, \ldots, C_k$):

$$info(T) = -\sum_{j=1}^{k} \frac{|C_j \cap T|}{|T|} * \log_2\left(\frac{|C_j \cap T|}{|T|}\right) \text{ bits}$$

(Entropie von T)

z.B.: k = 2

C_1: play

C_2: don‘t play

- Sei X ein Test, der T in $T_1, \ldots, T_n$ partitioniert.

  Dann ist der Erwartungswert für den Informationsgehalt einer Botschaft, die mitteilt, dass ein beliebig ausgewähltes Beispiel aus T_i in der Klasse C_j liegt (bei k Klassen $C_1, \ldots, C_k$):

$$info(T_i) = -\sum_{j=1}^{k} \frac{|C_j \cap T_i|}{|T_i|} * \log_2 \left(\frac{|C_j \cap T_i|}{|T_i|} \right) \text{ bits}$$

Damit ist der Erwartungswert über alle $T_1, \ldots, T_n$:

$$info_x(T) = \sum_{i=1}^{n} \frac{|T_i|}{|T|} * info(T_i)$$

z.B.: k = 2

C_1: play

C_2: don‘t play

z.B.: X: outlook; n = 3

T_1: sunny

T_2: overcast

T_3: rain

- *gain criterion* :

$$gain(x) = info(T) - info_X(T)$$

Maß für den Informationsgewinn durch Partitionierung von T durch Test X:

- wähle Test X, so dass gain (X) maximiert wird, d.h. möglichst großer Informationsgewinn durch aussagekräftiges Attribut X
- mit info(T) fix wähle ein Attribut X mit möglichst kleinem $info_X(T)$, d.h. Erwartungswert für noch benötigte Informationen zur Klassifikation ist möglichst klein

- *gain criterion* :

$$gain(x) = info(T) - info_X(T)$$

Bem.: Dies ist verwandt zum gemittelten Information Gain in III.3.5(iv):

$$\bar{I}_{gain}(c, A) = \frac{1}{s}\sum_{i=1}^{s} I_{gain}(c, A_i) = \frac{1}{s}\sum_{i=1}^{s} (H(c) - H(c\,|A_i)) = H(c) - \frac{1}{s}\sum_{i=1}^{s} H(c\,|A_i)$$

nur dass dort nur die Vorhersage einer Klasse C und nicht die Vorhersage in die Einteilung der Klassen C_1 , ... , C_k betrachtet wurde.

k = 2

C_1: play

C_2: don‘t play

Fortführung des Beispiels "Spielen im Freien" :

2 Klassen : Play, Don‘t Play

Klasse Play: 9 Fälle

Klasse Don‘t Play : 5 Fälle

damit:

$$info(T) = -\sum_{j=1}^{2} \frac{|C_j \cap T|}{|T|} * \log_2 \left(\frac{|C_j \cap T|}{|T|} \right) \text{ bits}$$

$$= -\left(\frac{9}{14} * \log_2 \left(\frac{9}{14} \right) + \frac{5}{14} \log_2 \left(\frac{5}{14} \right) \right) \text{ bits}$$

$$= 0.940 \ \ bits$$

(durchschnittlich benötigte Information zur Identifizierung der Klassenzugehörigkeit eines Beispiels aus T)

k = 2

C_1: play

C_2: don‘t play

X: outlook; n = 3

T_1: sunny

T_2: overcast

T_3: rain

- Attribut ‚outlook‘ erzeugt 3 Teilmengen:

$$T_1 : \text{outlook} = \text{sunny} \longrightarrow |T_1| = 5$$

$$T_2 : \text{outlook} = \text{overcast} \longrightarrow |T_2| = 4$$

$$T_3 : \text{outlook} = \text{rain} \longrightarrow |T_3| = 5$$

Und liefert nach Definition damit:

$$\text{info}_{\text{outlook}}(T) = \sum_{i=1}^{3} \frac{|T_i|}{|T|} * \text{info}(T_i)$$

$$= \frac{5}{14} * \left(-\frac{2}{5} * \log_2\left(\frac{2}{5}\right) - \frac{3}{5} * \log_2\left(\frac{3}{5}\right) \right)$$

$$+ \frac{4}{14} * \left(-\frac{4}{4} * \log_2\left(\frac{4}{4}\right) - \frac{0}{4} * \log_2\left(\frac{0}{4}\right) \right)$$

$$+ \frac{5}{14} * \left(-\frac{3}{5} * \log_2\left(\frac{3}{5}\right) - \frac{2}{5} \log_2\left(\frac{2}{5}\right) \right)$$

$$= 0.694 \quad \text{bits}$$

k = 2

C_1: play

C_2: don‘t play

Daraus folgt:

$$gain(outlook) = \text{info}(T) - \text{info}_{\text{outlook}}(T)$$

$$= (0.940 - 0.694) \text{ bits} = 0.246 \text{ bits}$$

Vergleich mit dem Attribut ‚windy‘:

windy erzeugt 2 Teilmengen:

X: windy; n = 2

T_1: true

T_2: false

$$T_1 : \text{windy} = \text{true} \longrightarrow |T_1| = 6$$

$$T_2 : \text{windy} = \text{false} \longrightarrow |T_2| = 8$$

- $\text{info}_{\text{windy}}(T) = \sum_{i=1}^{2} \frac{|T_i|}{|T|} * \text{info}(T_i) = \ldots = 0.892 \text{ bits}$
- damit

$$gain(windy) = (0.940 - 0.892) \text{ bits} = 0.048 \text{ bits}$$

Also wird ‚outlook‘ als stärker diskriminierendes Merkmal weiter oben im Baum verwandt als ‚windy‘.

Das gain criterion bevorzugt Tests mit vielen verschiedenen Testwerten
(Attribut mit großem Wertebereich), wie das folgende Beispiel zeigt.

$\Rightarrow$ Bildung von Teilmengen mit wenigen Fällen
$\Rightarrow$ im Extremfall einelementige Teilmengen
$\Rightarrow$ $info_X(T) = 0$

Aber für Klassifizierungszwecke ist die Bildung derartiger Teilmengen unerwünscht (Overfitting)! Deswegen wird (nach dem Beispiel) die Variante *gain ratio* des gain criterion vorgestellt.

Fortführung des Beispiels "Spielen im Freien" :

- füge neues Attribut ‘‘Datum‘‘ hinzu

  • Attribut mit vielen verschiedenen Werten

  • Attribut ‘‘Datum‘‘ liefert sehr hohen Informationsgewinn
    - Datumsangabe bestimmt eindeutig Wert des Zielattributes, d.h. Klassenzugehörigkeit
    - Attribut ‘‘Datum‘‘ würde als Wurzelattribut gewählt werden

  • Das Attribut ‘‘Datum‘‘ ist sehr gut geeignet für die Beschreibung der Trainingsdaten, aber nicht geeignet für Klassifikation neuer, bisher unbekannter Beispiele.

- *Idee: normalisiere* 'gain criterion' durch 'split info': *Erwartungswert* für Informationsgehalt einer Botschaft, die mitteilt, daß beliebig ausgewähltes *Beispiel in Teilmenge* T_i liegt (T wird durch Test X in Teilmengen $T_1,\ldots,T_n$ partitioniert)

$$split\ info(x) = -\sum_{i=1}^{n} \frac{|T_i|}{|T|} * \log_2\left(\frac{|T_i|}{|T|}\right) \text{ bits}$$

damit: $gain\ ratio(x) = \dfrac{\text{gain}(x)}{\text{split info}(x)}$

- da 'split info' für wenige große T_i *sehr klein* ist:

  maximiere 'gain ratio' unter Nebenbedingung, dass gain wenigstens so groß ist wie der *Durchschnittswert* von gain über alle möglichen Tests X.

Anwendung auf das Beispiel:

Attribut 'outlook' erzeugt 3 Teilmengen
mit 5, 4 und 5 Beispielen; damit

$$\text{split info(outlook)} = -\left(\frac{5}{14}\right) * \log_2\left(\frac{5}{14}\right) - \left(\frac{4}{14}\right) * \log_2\left(\frac{4}{14}\right) - \left(\frac{5}{14}\right) * \log_2\left(\frac{5}{14}\right) = 1.577 \text{ bits}$$

damit

$$\textit{gain ratio(outlook)} = \frac{\text{gain(outlook)}}{\text{split info(outlook)}}$$

$$= \frac{0.246}{1.577} = 0.156$$

b) Pruning

Problem der *Überspezialisierung* von Trainingsbeispielen:

I.a. ist der aus Trainingsdaten erzeugte Entscheidungsbaum zu komplex und hat eine zu hohe Fehlerrate bei neuen Beispielen.

Def.: **Overfitting (Überspezialisierung)** (Mitchell, 1997)

> Eine Klassenbeschreibung L ist in Bezug auf eine Menge von Trainingsdaten überspezialisiert, wenn es eine alternative Klassenbeschreibung L‘ gibt, so daß L in Bezug auf die Trainingsdaten eine geringere Fehlerrate hat als L‘, aber in Bezug auf alle möglichen Beispiele, d.h. insbesondere in Bezug auf bisher nicht bekannte Beispiele eine größere Fehlerrate hat als L‘.

- Da Attribute von Trainingsbeispielen zu einem gewissen Grad *zufällig* sind und *nicht alle* für die Klassifikation *wichtigen* Informationen enthalten, ist *Gefahr des Overfitting* immer gegeben.

- Lösung: vereinfache erzeugten Entscheidungsbaum durch Pruning (Abschneiden).

- <u>Pruning speziell bei C4.5:</u>
  Ersetze *Teilbaum*
  - ° durch einen *Blattknoten*
  - ° bzw. durch den *besten Zweig* des Teilbaums

  sofern sich dadurch die erwartete Fehlerrate für neue Beispiele verringert

- Bem.: Pruning *erhöht* stets die Fehlerrate für *gegebene* Trainingsbeispiele!

***Original decision tree*:**

```
physician fee freeze = n:
|   adoption of the budget resolution = y: democrat (151)
|   adoption of the budget resolution = u: democrat (1)
|   adoption of the budget resolution = n:
|   |   education spending = n: democrat (6)
|   |   education spending = y: democrat (9)
|   |   education spending = u: republican (1)
physician fee freeze = y:
|   synfuels corporation cutback = n: republican (97/3)
|   synfuels corporation cutback = u: republican (4)
|   synfuels corporation cutback = y:
|   |   duty free exports = y: democrat (2)
|   |   duty free exports = u: republican (1)
|   |   duty free exports = n:
|   |   |   education spending = n: democrat (5/2)
|   |   |   education spending = y: republican (13/2)
|   |   |   education spending = u: democrat (1)
physician fee freeze = u:
|   water project cost sharing = n: democrat (0)
|   water project cost sharing = y: democrat (4)
|   water project cost sharing = u:
|   |   mx missile = n: republican (0)
|   |   mx missile = y: democrat (3/1)
|   |   mx missile = u: republican (2)
```

***After pruning*:**

```
physician fee freeze = n: democrat (168/2.6)
physician fee freeze = y: republican (123/13.9)
physician fee freeze = u:
    mx missile = n: democrat (3/1.1)
    mx missile = y: democrat (4/2.2)
    mx missile = u: republican (2/1)
```

Abbildung VI.1-5: Decision tree before and after pruning (Quinlan 1993)

Beispiel (vgl. Abbildung. VI.1-5)

- 1. Teilbaum ‚physician fee freeze' = n :
  trennt 1 Republikaner von 167 Demokraten
- Pruning zum Blattknoten ‚democrat' :
  1 Trainingsbeispiel wird jetzt falsch klassifiziert

Vorgehensweise zum Schätzen der Fehlerrate:

° Alternative 1:
trenne geg. Menge von Beispielen in
Trainingsbeispiele und *Testbeispiele*
und verwende Testbeispiele für die Abschätzung
der Fehlerrate für neue Fälle

- Probem: Die Menge der Trainingsbeispiele wird kleiner.

  → *Cross validation* als Abhilfe

k-fache Kreuzvalidierung (k-fold cross validation)

- teile vorhandene Beispiele in k gleich große Teilmengen auf

- jeweils (k-1) Teilmengen werden als Trainingsbeispiele verwendet, verbleibende Teilmenge als Testbeispiele

- führe Lernvorgang und anschließende Validierung k-fach durch, mit jeweils anderer Menge von Testbeispielen

- wähle Pruning-Schritt derart, daß Fehlerrate für Testbeispiele möglichst klein ist

° Alternative 2:

° verwende als Grundlage den aus allen Trainingsbeispielen erzeugten Entscheidungsbaum

• Vorteil: Alle vorhandenen Daten werden zum Lernen genutzt. Wichtig bei wenigen Ausgangsdaten

• Nachteil: Fehlerrate kann nur abgeschätzt werden für neue Beispiele

- *C4.5* verwendet *Alternative 2* mit folgender Idee:

° Blattknoten deckt N Trainingsbeispiele ab (Wie repräsentativ ist N?), davon sind E falsch zugeordnet

• Fehlerrate E/N ist bekannt

• Schließe auf Fehlerrate für alle (unbekannten) Beispiele, die durch Blatt abgedeckt werden, per Binominalverteilung. (Eigentlich darf dies nicht gemacht werden, da die geforderten Annahmen nicht zutreffen, in der Praxis funktioniert es aber doch häufig.)

• *Pruning* darf geschätzte Fehlerrate *nicht erhöhen*

Evaluation on training data (300 items):

Before Pruning		After Pruning		
Size	Errors	Size	Errors	Estimate
25	8(2.7%)	7	13(4.3%)	(6.9%)

Evaluation on test data (135 items):

Before Pruning		After Pruning		
Size	Errors	Size	Errors	Estimate
25	7(5.2%)	7	4(3.0%)	(6.9%)

Abbildung VI.1-6: Results with congressional voting data (Quinlan 1993)

c) Windowing (for dealing with *large* datasets)

-start the construction of the decision tree with a subset of the training examples- called a window

- select subset in a way that the distribution of classes in the initial window is as uniform as possible
- first decision tree is built from the initial window
- classify remaining training examples with the new decision tree
- some of these examples are misclassified
    - include subset of them in the next window
      (C4.5 chooses at least 50%)
- stop iteration if
    - all training examples are correctly classified or
    - sequence of trees is not becoming more accurate

d) Erzeugung von Produktionsregeln

- Komplexe Entscheidungsbäume sind schwer zu verstehen, da jeder Test im *Kontext* aller vorhergehenden Tests zu interpretieren ist.
- Lösung:
  - Betrachte alle Tests auf *Pfad* von Wurzel zu aktuellem Knoten
  - und transformiere die Pfadtests in Bedingungen für *Produktionsregeln* der Form

    IF $test_1 \wedge test_2 \wedge .. \wedge test_n$
    THEN class = C1

  - Eine Klasse wird als *Default-Klasse* verwendet.

good, bad.

duration:	continuous.
wage increase first year:	continuous.
wage increase second year:	continuous.
wage increase third year:	continuous.
cost of living adjustment:	none, tcf, tc.
working hours:	continuous.
pension:	none, ret_allw, empl_contr.
standby pay:	continuous.
shift differential:	continuous.
education allowance:	yes, no.
statutory holidays:	continuous.
vacation:	below average, average, generous.
longterm disability assistance:	yes, no.
contribution to dental plan:	none, half, full.
bereavement assistance:	yes, no.
contribution to health plan:	none, half, full.

Abbildung VI.1-7: File defining labor-neg classes and attributes

(Quinlan 1993)

```
C4.5 [release 5] decision tree generator        Fri Dec 6 13:33:54 1991

      Options:
            File stem <labor-neg>
            Trees evaluated on unseen cases

Read 40 cases (16 attributes) from labor-neg.data

Decision Tree:

wage increase first year ≤ 2.5 :
|   working hours ≤ 36 : good (2.0/1.0)
|   working hours > 36 :
|   |   contribution to health plan = none: bad (5.1)
|   |   contribution to health plan = half: good (0.4/0.0)
|   |   contribution to health plan = full: bad (3.8)
wage increase first year > 2.5 :
|   statutory holidays > 10 : good (21.2)
|   statutory holidays ≤ 10 :
|   |   wage increase first year ≤ 4 : bad (4.5/0.5)
|   |   wage increase first year > 4 : good (3.0)

Simplified Decision Tree:

wage increase first year ≤ 2.5 : bad (11.3/2.8)
wage increase first year > 2.5 :
|   statutory holidays > 10 : good (21.2/1.3)
|   statutory holidays ≤ 10 :
|   |   wage increase first year ≤ 4 : bad (4.5/1.7)
|   |   wage increase first year > 4 : good (3.0/1.1)

Tree saved

Evaluation on training data (40 items):

        Before Pruning          After Pruning
        ----------------        ---------------------------
        Size      Errors        Size      Errors      Estimate

          12    1 ( 2.5%)          7    1 ( 2.5%)    (17.4%)   <<


Evaluation on test data (17 items):

        Before Pruning          After Pruning
        ----------------        ---------------------------
        Size      Errors        Size      Errors      Estimate

          12    3 (17.6%)          7    3 (17.6%)    (17.4%)   <<


         (a)   (b)    <-classified as
        ----  ----    ------------
          10     1    (a): class good
           2     4    (b): class bad
```

Abbildung VI.1-8:
Output of C4.5 on labor-neg data (Quinlan 1993)

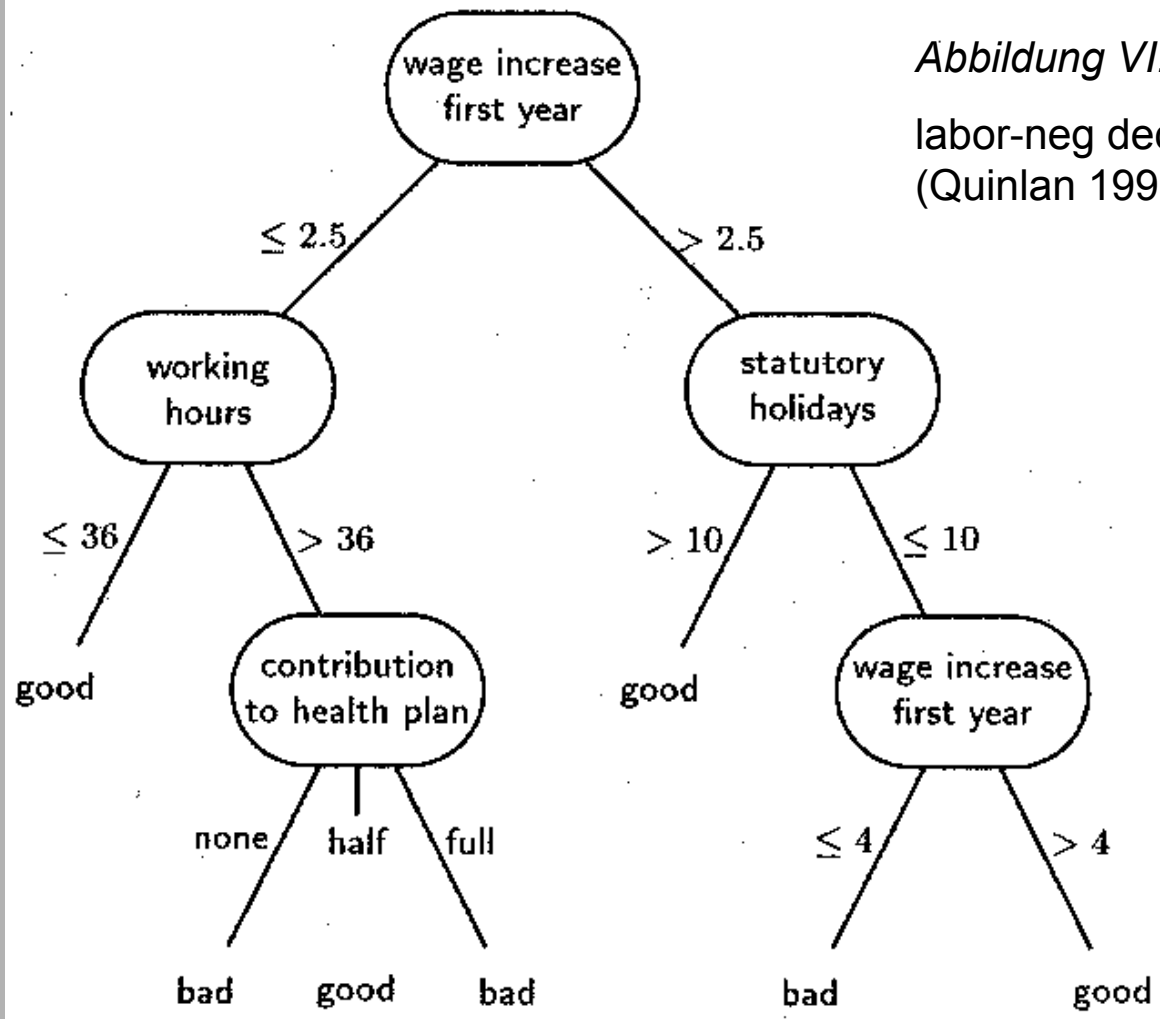

Abbildung VI.1-9:

labor-neg decision tree in graph form (Quinlan 1993)

C4.5 [release 5] rule generator Fri Dec 6 13:34:20 1991

Options:
File stem <labor-neg>
Rulesets evaluated on unseen cases

Read 40 cases (16 attributes) from labor-neg

Processing tree 0

Final rules from tree 0:

Rule 5:
wage increase first year > 2.5
statutory holidays > 10
--> class good [93.0%]

Rule 4:
wage increase first year > 4
--> class good [90.6%]

Rule 3:
wage increase first year ≤ 4
statutory holidays ≤ 10
--> class bad [87.1%]

Rule 2:
wage increase first year ≤ 2.5
working hours > 36
--> class bad [85.7%]

Default class: good

Evaluation on training data (40 items):

Rule	Size	Error	Used	Wrong		Advantage	
5	2	7.0%	19	0	(0.0%)	0 (0|0)	good
4	1	9.4%	3	0	(0.0%)	0 (0|0)	good
3	2	12.9%	10	0	(0.0%)	5 (5|0)	bad
2	2	14.3%	4	0	(0.0%)	4 (4|0)	bad

Tested 40, errors 0 (0.0%) <<

(a)	(b)	<--classified as
26		(a): class good
	14	(b): class bad

Evaluation on test data (17 items):

Rule	Size	Error	Used	Wrong		Advantage	
5	2	7.0%	9	1	(11.1%)	0 (0|0)	good
4	1	9.4%	3	1	(33.3%)	0 (0|0)	good
3	2	12.9%	1	0	(0.0%)	1 (1|0)	bad
2	2	14.3%	3	0	(0.0%)	3 (3|0)	bad

Tested 17, errors 2 (11.8%) <<

(a)	(b)	<--classified as
11		(a): class good
2	4	(b): class bad

Abbildung VI.1-10:
Result of postprocessing to rules (Quinlan 1993)

- Regeln können gegebenenfalls vereinfacht werden durch Entfernen von Tests aus dem Bedingungsteil:
  Beispiel: In Regel 4 in Abbildung VI.1-10 ist die Bedingung ‚statutary holidays $\leq$ 10' entfernt worden.

- Vorgehensweise für Klassifikation eines *neuen* Beispiels:
  - ° gehe Regeln der Reihe nach durch (Reihenfolge ist relevant)
  - ° erste Regel, deren Bedingungsteil erfüllt ist, wird ausgewählt
  - ° rechte Seite der Regel bestimmt Klassenzugehörigkeit für betrachtetes Beispiel
  - ° ist von keiner Regel der Bedingungsteil erfüllt, wird Default-Klasse gewählt

e) Fazit

- C4.5 weitverbreitetes Verfahren zur Erzeugung von Entscheidungsbäumen und zugehörigen Produktionsregeln

- Verfahren abhängig von
  - ° Bewertungsfunktion für Attributauswahl
  - ° Schätzung der Fehlerrate bei Pruning
  - ° Schätzung der Fehlerrate bei Erzeugung und Vereinfachung von Produktionsregeln

- vergleichbare Verfahren
  - ° ID3 (Quinlan 1983)
  - ° CN2 (Clark/Niblatt 1989)