

**Methoden zur computerbildanalytischen Pflanzenidentifikation am Beispiel  
dendrologischer Bestimmungen**

Dem Fachbereich Gartenbau der Universität Hannover

zur Erlangung der Würde eines  
Dr. rer. hort. habil.  
vorgelegte Habilitation

von

Dr. rer hort. Thomas Rath  
geb. 07.08.1961 in Meschede

Dezember 1996

# Methoden zur computerbildanalytischen Pflanzenidentifikation am Beispiel dendrologischer Bestimmungen

<u>Inhaltsverzeichnis</u>	Seite
Formelzeichen, Indices	
1. Einleitung, Motivation und Zielsetzung	1
2. Bisherige Arbeiten auf dem Gebiet der pflanzenbauorientierten Computerbildanalyse	3
3. Dendrologische Verfahren und Merkmale der Pflanzenbestimmung	6
4. Grundlagen der Computerbildanalyse und Definitionen	11
4.1 Darstellung und Codierung von Bildinformationen	11
4.2 Allgemeine Vorgehensweise der Computerbildverarbeitung	14
4.3 Bildbearbeitung und -manipulation	16
4.3.1 Bearbeitung und Manipulation von Grauwertmatrizen	16
4.3.2 Bearbeitung und Manipulation von Punktmengen	20
4.4 Merkmalextraktion aus Grauwertbildern und Punktmengen	32
4.5 Datenauswertung zur Identifikation und Klassifikation	35
4.5.1 Allgemeine Einteilung	35
4.5.2 Statistische Verfahren	35
4.5.3 Wissensbasierte Systeme und Fuzzy-Logik	41
4.5.4 Neuronale Netzwerke	45
5. Material und Methoden	50
5.1 Verwendetes Pflanzenmaterial und Bildaufnahmen	50
5.2 Blattmerkmale und deren Parametrisierung	52
5.3 Entwickelte Bildbearbeitungsalgorithmen	60
5.3.1 Bildaufbereitung	60
5.3.2 Erkennung und Auswertung des Blattstieles und des Blattaufbaues	61
5.3.3 Erkennung und Auswertung der Spreitenbasis und der Spreitenspitze	69

	Seite
5.3.4 Erkennung und Auswertung der Blattspreite	73
5.3.5 Erkennung und Auswertung der Einzelblättchen	77
5.3.6 Erkennung und Auswertung der Blattlappen	88
5.3.7 Erkennung und Auswertung des Blattrandes	91
5.4 Entwickelte Bestimmungsmodelle	97
5.4.1 Allgemeines zur Datenaufbereitung und -verwendung	97
5.4.2 Modellansatz auf der Basis zweiwertiger Produktionsregelsysteme	99
5.4.3 Fuzzy-Logik-orientierter Modellansatz	102
5.4.4 Modellansätze auf der Basis neuronaler Netzwerke	104
5.4.5 Statistische Modellansätze	107
5.5 Eingesetzte Hard- und Software	107
6. Ergebnisse	108
6.1 Ergebnisse der entwickelten Algorithmen zur Merkmalextraktion	108
6.1.1 Allgemeines	108
6.1.2 Ergebnisse zur Blattstiel- und Blattachsenerkennung	108
6.1.3 Ergebnisse zur Formerkennung der Blattspreite, zur Blattanzahlberechnung, zur Blattlappenerkennung und zur Blattrandanalyse	111
6.2 Allgemeine statistische Kennzahlen der Merkmalextraktion	118
6.3 Größen- und Lageinvarianz der Merkmale	122
6.3 Ergebnisse der computerbildanalytischen Pflanzenbestimmung	126
6.3.1 Ergebnisse wissensbasierter und statistischer Modellansätze	126
6.3.2 Ergebnisse kombinierter Modellansätze	130
6.3.3 Ergebnisse künstlicher neuronaler Netzwerke	133
7. Diskussion und Schlußfolgerungen	135
7.1 Diskussion der Methoden zur Bildbearbeitung und Merkmalextraktion	135
7.1.1 Grundlegende methodische Ansätze zur Bildbearbeitung	135
7.1.2 Spezielle Ansätze zur Merkmalextraktion und -parametrisierung	137
7.1.3 Auswahl der Blattmerkmale	140
7.2 Diskussion der Methoden zur Merkmalauswertung und Dateninterpretation	142
7.3 Diskussion der Funktionalität des erstellten Systems	147

	Seite
7.4 Einsatz und Nutzung der entwickelten Ansätze und des Gesamtsystems	148
7.5 Zukünftige Entwicklungen, Verbesserungen und Visionen	149
8. Zusammenfassung	150
9. Literatur	152
Anhang	167

Formelzeichen, Indices (Wertebereiche beziehen sich auf die zuerst genannte Variable)

$a_{ij}$	Komponente der Grauwertmatrix <b>A</b> ( i-te Zeile, j-te Spalte )	$\in \mathbb{N}_0$
$b_{ij}$	Komponente der Grauwertmatrix <b>B</b> ( i-te Zeile, j-te Spalte )	$\in \mathbb{N}_0$
$c_{ij}, c'_{ij}, c''_{ij}$	Komp. d. Grauwertmatr. <b>C</b> bzw. <b>C'</b> , <b>C''</b> ( i-te Zeile, j-te Spalte)	$\in \mathbb{N}_0$
$d_z$	Minkowski-z-Metrik	
$d_E$	euklidische Abstandsfunktion	
$d_{MS}$	Mahalanobis-Abstand unter Verwendung der Kovarianzmatrix <b>S</b>	
det	Determinante	
$f$	allgemeine Funktion	
$f_t$	Transferfunktion	
$f_{d_i}$	Diskriminanzfunktion	
$f_z \tilde{F}_i$	Zugehörigkeitsfunktion zur unscharfen Menge $\tilde{F}_i$	
$\mathbf{g}, g_i, g, \mathbf{h}, h_i, h$	Punktvektor, (Zeile, Spalte), $\mathbf{g} = (g_1, g_2)$ , $\mathbf{h} = (h_1, h_2)$	$\in \mathbb{Z}^2$
$i, j, k, l$	Laufindex, Numerierung, Zähler	$\in \mathbb{N}_0$
$m, m_i, n, n_i$	Zählvariable, Zähler	$\in \mathbb{N}_0$
$\max_i, \min_i$	Maximum bzw. Minimum über alle $i$	
$p_i$	Codewert	$\in \mathbb{N}_0$
$q_i, q^*, q^*$	allgemeine Aussagen, Fakten	
$\mathbf{r}, r, r_i, r_{ij}$	allgemeine Variable bzw. Punktvektor, $\mathbf{r} = (r_1, r_2)$	$\in \mathbb{R}^2$
$\mathbf{s}, s_i, s, s$	allgemeine Variable bzw. Punktvektor, $\mathbf{s} = (s_1, s_2)$	$\in \mathbb{R}^2$
$t_i$	Codewert	$\in \mathbb{N}_0$
$\mathbf{v}, v, v_i, \mathbf{w}, w, w_i$	Punktvektor, (Zeile, Spalte), $\mathbf{v} = (v_1, v_2)$ , $\mathbf{w} = (w_1, w_2)$	$\in \mathbb{Z}^2$
$\mathbf{x}, x, x_i, x_{ij}, x_{ijk}$	allgemeiner Wertevektor, $\mathbf{x} = (x_1, x_2, x_3, \dots)$ , Wertevariable	$\in \mathbb{R}^n$

$\mathbf{y}, y, y_i, y_{ij}$	allgemeiner Wertevektor, $\mathbf{y} = (y_1, y_2, y_3, \dots)$ , WertevARIABLE	$\in \mathbb{R}^n$
$z, z_i, z_{ij}$	Merkmalsvariable, Zwischenwertvariable, Optimierungswert	$\in \mathbb{R}$
$\mathbf{A}, \mathbf{B}, \mathbf{B}_{(n_1, n_2)}, \mathbf{C}, \mathbf{C}', \mathbf{C}''$	Grauwertmatrix	$\in \mathbb{N}^{n_1 \times n_2}$
$F_i$	Aussage, Aussagenmenge	
$\tilde{F}_i$	unscharfe (fuzzy) Menge	
$\mathbf{G}_i, \mathbf{G} = \{G_1 = \{\mathbf{g}_1 = (g_1, g_2), \mathbf{g}_2, \dots\}, G_2, \dots\}$	Punktmenge(n)	$\subseteq \mathbb{Z}^2$
$G, G_i$	Punktmenge, Region	$\subseteq \mathbb{Z}^2$
$\mathbf{H}_i, \mathbf{H} = \{H_1 = \{\mathbf{h}_1 = (h_1, h_2), \mathbf{h}_2, \dots\}, H_2, \dots\}$	Punktmenge(n)	$\subseteq \mathbb{Z}^2$
$H, H_i$	Punktmenge, Region	$\subseteq \mathbb{Z}^2$
$L_i$	Lerndatensatz der Gruppe $i$	
$Q_i$	allgemeine Aussagenmenge	
$\mathbf{R}_i, \mathbf{R} = \{R_1 = \{\mathbf{r}_1 = (r_1, r_2), \mathbf{r}_2, \dots\}, R_2, \dots\}$	Punktmenge(n)	$\subseteq \mathbb{R}^2$
$\mathbf{S}, \mathbf{S}_i$	Kovarianzmatrix	
$T_i$	Code, Kettencode	
$\mathbf{V}_i, \mathbf{V} = \{V_1 = \{\mathbf{v}_1 = (v_1, v_2), \mathbf{v}_2, \dots\}, V_2, \dots\}$	Punktmenge(n), Flächenfolge	$\subseteq \mathbb{Z}^2$
$V, V_i$	Punktmenge, Region	$\subseteq \mathbb{Z}^2$
$\mathbf{W}_i, \mathbf{W} = \{W_1 = \{\mathbf{w}_1 = (w_1, w_2), \mathbf{w}_2, \dots\}, W_2, \dots\}$	Punktmenge(n)	$\subseteq \mathbb{Z}^2$
$W, W_i$	Punktmenge, Region	$\subseteq \mathbb{Z}^2$
$Z$	Flächen- oder Differenzenfolge	
$\alpha$	Irrtumswahrscheinlichkeit	[%]
$\beta$	alphabetischer Operationsbezeichner	$\in \{A\dots Z, a\dots z\}$
$\gamma, \gamma_i$	Drehwinkel, Ausrichtungswinkel	[rad]

$\delta_i$	Fehler, Abweichung vom Sollwert	[ - ]
$\zeta$	Konvexitätskriterium	[ - ]
$\lambda, \lambda_i, \lambda_{ij}$	Faktor, Zwischenwertvariable, Konstante	$\in \mathbb{R}$
$\mu_i$	Erwartungswert Merkmal $i$	[Pixel], [ - ]
$\sigma_{ij}$	Standardabweichung Merkmal $i$ in Gruppe $j$	[Pixel], [ - ]
$\varphi, \varphi_i, \varphi_{ij}, \varphi'_{ij}, \bar{\varphi}_{ij}$	Blattmerkmal, arithmetisches Mittel Blattmerkmal	[Pixel], [ - ]
$\theta$	Ausrichtungswinkel Blattachse	[rad]
$\Gamma_A$	euklidischer Abstand (Merkmaloperator)	
$\Gamma_H$	Konvexität (Merkmaloperator)	
$\Gamma_P$	Pixelfläche (Merkmaloperator)	
$\Gamma_R, \Gamma_{R_i}$	Radius, $R_1 =$ Länge, $R_2 =$ Breite (Merkmaloperator)	
$\Gamma_T$	Anzahl Teilflächen (Merkmaloperator)	
$\Gamma_U$	Konturlinienumfang (Merkmaloperator)	
$\Gamma_W$	Ausrichtungswinkel (Merkmaloperator)	
$\Delta$	Differenzoperator	
$\sum_i, \sum_{n=m}^k$	Summenoperator (Summe über alle $i$ bzw. von $m$ bis $k$ )	
$\Phi_E$	Ellipse (geometrischer Punktmengenoperator)	
$\Phi_S$	geometrischer Schwerpunkt (geometrischer Punktmengenoperator)	
$\Phi_H$	konvexe Hülle (geometrischer Punktmengenoperator)	
$\Phi_K$	Kreis (geometrischer Punktmengenoperator)	
$\Phi_Q$	Quadrat (geometrischer Punktmengenoperator)	
$\Phi_R$	Rechteck (geometrischer Punktmengenoperator)	
$\Phi^E$	umschließende Ellipse (geometrischer Punktmengenoperator)	

$\Phi^K$	umschließender Kreis (geometrischer Punktmengeoperator)
$\Phi^Q$	umschließendes Quadrat (geometrischer Punktmengeoperator)
$\Phi^R$	umschließendes Rechteck (geometrischer Punktmengeoperator)
$\Psi_B$	Grauwertspreizung, Binarisierung (Grauwertoperator)
$\Psi_F$	Faltung (Grauwertoperator)
$\Omega_A$	affine Abbildung - Drehung, Verschiebung (allgem. Punktmengeop.)
$\Omega_F$	iteratives Füllen von Regionen (allgemeiner Punktmengeoperator)
$\Omega_D, \Omega_D^k$	Dilation (allgemeiner Punktmengeoperator)
$\Omega_E, \Omega_E^k$	Erosion (allgemeiner Punktmengeoperator)
$\Omega_G$	Generierung Punktmenge (allgemeiner Punktmengeoperator)
$\Omega_M$	affine Abbildung - Skalierung (allgemeiner Punktmengeoperator)
$\Omega_P$	Punktdilation (allgemeiner Punktmengeoperator)
$\Omega_R$	Punktmengerundung, -interpolation (allgemeiner Punktmengeop.)
$\Omega_T$	iterative Teilregionenbildung (allgemeiner Punktmengeoperator)
$\Omega_{V_a}$	Verdünnung auf Skelettanfangspunkte (allg. Punktmengeoperator)
$\Omega_{V_k}$	Verdünnung auf Kreuzungspunkte im Skelett (allg. Punktmengeop.)
$\Omega_{V_r}$	Verdünnung auf den Rand, Konturlinie (allgemeiner Punktmengeop.)
$\Omega_{V_s}$	Verdünnung auf ein Skelett, Skelettbildung (allgem. Punktmengeop.)
$\overline{\Omega}_\beta^n$	n-fach iterative Operation $\beta$ (allgemeiner Punktmengeoperator)
$\diamond_K$	Kettencode (Kettencodeoperator)
$\diamond_L$	Wechselängencode (Kettencodeoperator)
$\diamond_R$	Richtungscode (Kettencodeoperator)
$\diamond_W$	Richtungswechselcode (Kettencodeoperator)

$\in$	Element ( $w \in W$ bedeutet: $w$ ist Element von $W$ )
$\{   \}$	Mengen in Aussageform ( $\{V \mid V \in G\}$ bedeutet: $V$ mit $V \in G$ )
$\{\}$	leere Menge
$\neg$	Komplement ( $\neg V$ bedeutet: Gesamtmenge außer $V$ )
$\setminus$	Mengendifferenz ( $W \setminus V$ bedeutet: $W$ ohne $V$ )
$\cup, \cup$	Vereinigung, Vereinigungsmenge
$\cap, \cap$	Schnitt, Schnittmenge
$\subseteq$	Untermenge, Teilmenge ( $V \subseteq W$ bedeutet: $V$ ist Teilmenge von $W$ )
$\wedge$	logisches Und
$\vee$	logisches Oder
$\times$	Kreuzprodukt

## 1. Einleitung, Motivation und Zielsetzung

Moderne Produktionsverfahren im Gartenbau sind gekennzeichnet durch eine zunehmende Automatisierung unter Nutzung fachspezifischer Information. Grundlegende Voraussetzung ist die Verwendung visueller Eindrücke, die maschinell oder anthropogen ausgewertet werden. Beispiele finden sich in allen Bereichen des Pflanzenbaues: Pflanzenarten und -sorten werden aufgrund spezifischer botanischer Merkmale differenziert, Kulturmaßnahmen wie Düngung oder Pflanzenschutz richten sich nach spezifischen Schad- oder Mangelsymptomen, Klimatisierungsmaßnahmen in Gewächshäusern hängen vom sichtbaren Wachstumsverlauf der Kulturpflanzen ab oder Qualitätseinstufungen gärtnerischer Endprodukte werden anhand äußerer Merkmale vorgenommen.

Forschungs- und Entwicklungsarbeiten in den entsprechenden Fachgebieten konnten Ursachen-Wirkungs-Zusammenhänge ermitteln und resultieren in Beschreibungen, Farbtafeln, Bilddatenbanken oder - strenger formalisiert - in Bestimmungs- oder Klassifikationsschlüsseln, mathematischen Modellen und entscheidungsunterstützenden Systemen.

Auf der physikalisch-technischen Seite ermöglichen moderne Bildaufnahme- und -bearbeitungssysteme eine Erfassung, Speicherung und Auswertung optischer Informationen, die zumindest in der Auflösung und der spektralen Variabilität bzw. Empfindlichkeit dem optischen Aufnahmesystem des Menschen überlegen sind.

Trotz dieser günstigen Voraussetzungen ist eine direkte automatische Nutzung visueller Eindrücke und Informationen im Gartenbau, zum Beispiel in Automaten oder entscheidungsunterstützenden Systemen, selten. Offenbar ist die Verknüpfung zwischen Bildaufnahme und fachspezifischer Ausnutzung schwieriger als im ersten Augenblick erscheint. Da die visuelle Wahrnehmung des Menschen durch eine enorme Komplexität sowohl auf organischer als auch auf neurologischer Ebene gekennzeichnet ist, bereitet die Übertragung menschlicher Wahrnehmungsprozesse in künstliche Systeme enorme Schwierigkeiten (vgl. POGGIO und BEYMER 1996). Dies ist um so gravierender, je anspruchsvoller die zu bewältigende Aufgabe ist und je variabler, vielschichtiger und allgemeiner die zur Verfügung stehenden Bildinformationen sind. Gerade für den Bereich des Gartenbaus, der sich nicht mit technisch normierten Industrieprodukten, sondern mit variablen biologischen Objekten

beschäftigt, kommt diesem Aspekt besondere Bedeutung zu. Eine inhaltlich komplexe und damit schwierige Interpretation von Bildinformationen ist hier in nahezu allen Fällen erforderlich.

Ziel der vorliegenden Arbeit ist es daher, den Prozeß der Verknüpfung von Bilddaten mit fachspezifischem Wissen zu untersuchen und weiterzuentwickeln. Hierzu wurde das Themengebiet der dendrologischen Pflanzenbestimmung anhand von Laubblättern gewählt, da es für viele im Gartenbau vorliegende Problembereiche (Unkrautererkennung, Sortenunterscheidung, Pflanzenschädenerkennung etc.) exemplarischen Charakter hat und auf diese übertragbar ist. Hinzu kommt, daß bisher keine Arbeiten zu dieser Thematik vorliegen.

Ogleich in einem angewandten Forschungsgebiet wie das des Gartenbaus inhaltliche Fragestellungen von großer Bedeutung sind, setzt die Arbeit methodische Schwerpunkte, um zukünftigen Entwicklungen auf ähnlichen Gebieten Hilfestellung zu geben. Im ersten Teil der Arbeit werden bisherige Untersuchungen auf dem Gebiet der Computerbildanalyse und die Grundlagen für das weitere Verständnis der Ausführungen dargestellt. Anschließend werden die entwickelten Ansätze beschrieben, wobei sowohl die mathematisch exakte Formulierung als auch die bildliche Darstellung für den weniger formal orientierten Leser verwendet wird. Abschließend erfolgt die Überprüfung der entwickelten Ansätze zur Pflanzenbestimmung anhand von Testdaten und die Diskussion der Ergebnisse. Im Anhang befinden sich Beispielbilder der untersuchten Arten und Zeichnungen zu den verwendeten botanischen Fachbegriffen.

## 2. Bisherige Arbeiten auf dem Gebiet der pflanzenbauorientierten Computerbildanalyse

Durch zunehmende Kapazitäten moderner Rechenanlagen hat die automatische Verarbeitung von Bildinformationen im Gartenbau und in der Landwirtschaft in den letzten Jahren stark an Bedeutung gewonnen. Allgemeine Forschungs- und Entwicklungsarbeiten auf dem Gebiet der Bildverarbeitung verbessern ständig die Möglichkeiten, die sich für den Gartenbau aus der Technologie ergeben. Eine allgemeine Beschreibung des gegenwärtigen Standes gibt das MINISTERIUM FÜR WIRTSCHAFT, MITTELSTAND UND TECHNOLOGIE DES LANDES NORDRHEIN-WESTFALEN (1995) in der Studie "Stand und Trends der Bildverarbeitung in NRW". TILLET (1991) stellt Möglichkeiten und Anwendungen im Bereich des Pflanzenbaus dar. HACK und RATH (1992) und RATH (1994) beschreiben Potentiale speziell im Gartenbau.

Bisherige Arbeiten auf dem Gebiet der Computerbildverarbeitung können im Pflanzenbau den Bereichen Ernte/Vermehrung, Pflanzenmessung, Sortierung und Pflanzenidentifikation zugeordnet werden.

Zahlreiche Untersuchungen wurden bisher im Bereich der Ernteautomatisierung im Gartenbau mit Hilfe der Computerbildanalyse durchgeführt. So wurde bereits versucht, Ernteobjekte mit computerbildanalytischen Verfahren zu lokalisieren und anschließend mit Roboter- oder Automaten systemen zu ernten (z.B. MOLTO et al. 1992, WHITTAKER et al. 1987, vgl. auch SARIG 1993). Andere Untersuchungen beschäftigten sich mit der Reifebestimmung von Produkten (z. B. QUI und SHEARER 1992). Obwohl die entwickelten Systeme z.T. sehr gute Ernteergebnisse erzielten, ist zum heutigen Zeitpunkt kein Ernteroboter oder -automat kommerziell verfügbar. Erfolgversprechender scheinen Ansätze zu sein, bei denen die Bildverarbeitung die Ernte- oder Kulturarbeiten nur unterstützt. KEICHER et al. (1995), MOLLER NIELSEN et al. (1995) sowie FEHR und GERRISH (1995) beschreiben z.B. die Möglichkeit der Schleppersteuerung in Reihenkulturen mit Hilfe der Bildverarbeitung. ALCHANATIS et al. (1993) und SCHAUFLER und WALKER (1995) stellen Einsätze der Bildverarbeitung im Bereich der Gewebekulturen vor. HUMPHRIES und SIMONTON (1993) analysierten Geranienstecklinge.

Pflanzenwachstumsmessungen werden im Forschungsbereich häufig computerbildanalytisch ausgewertet. Neben reinen Flächenberechnungen kommen zunehmend auch Farbauswertungen zum Einsatz. Meß- und Auswertesysteme sind kommerziell verfügbar (z.B. DELTA-T DEVICES 1996). Darüber hinaus wird versucht, mit Hilfe der Computerbildanalyse Pflanzenschäden oder -störungen zu entdecken und zu bestimmen (z.B. HETZRONI und MILES 1992). Andere Ansätze verfolgen das Ziel, Pflanzenwachstumsmodelle mit Hilfe der Computerbildanalyse anzupassen, zu überprüfen oder für weitere Einsatzzwecke zu verwenden (EVERS et al. 1987, HACK 1992, BENNEDSEN 1992, TROOIJEN und HEERMANN 1992, LING und RUZHITSKY 1996, SHIMIZU und HEINS 1995, WILHOIT 1994).

Am weitesten fortgeschritten ist der Einsatz der Computerbildanalyse im Bereich der Sortiereinrichtungen. Erste Arbeiten wurden bereits 1986 von ZAYAS et al. (1986) zur Trennung von Getreide vorgestellt. Ausführungen zu Sortieraufgaben (z.B. Apfelsortierung nach Schadstellen o.ä.) finden sich z.B. bei SHEARER und PAYNE (1990), YANG (1996), HOTHER et al. (1995), ZWIGGELAAR et al. (1996), LIAO et al. (1993), TAO et al. (1995a), TRUPPEL und HEROLD (1996) oder STEINMETZ et al. (1994). Echtzeitsysteme werden entwickelt (siehe RIGNEY und KRANZLER 1988, LIAO et al. 1994). Im Bereich der Zierpflanzensortierung existieren bereits praxisreife Anwendungen. Firmen bieten Systeme zur Klassifikation von Topfpflanzen nach Blütengrößen und Pflanzenabmessungen auf der Basis unterschiedlicher Klassifikatoren an (MAYER 1992, VISSER 1995 bzw. TIMMERMANS und HULZEBOSCH 1995, MEULEMANN 1995, u.a.). Für schwierigere Sortierobjekte stehen computerbildanalytische Erweiterungsmodule für konventionelle Sortiereinrichtungen zur Verfügung (z.B. für Rosen, OLIMEX, 1995).

Im Bereich der Pflanzenidentifikation und -bestimmung wurden bisher ausschließlich Unkräuter analysiert. Erste Arbeiten extrahierten aus digitalisierten Pflanzenaufnahmen verschiedene Formmerkmale und verdichteten sie zu Identifikationsmodellen (GUYER et al. 1984, PETRY 1989, WOEBBECKE 1995). GUYER et al. 1993 versuchten, diese Modellansätze um Expertenregeln (wissensbasiert) zu erweitern. Eine allgemeine theoretische Untersuchung über die Identifikation von Blattformen und deren Parametrisierung beschreiben YONEKAWA et al. (1996). SÖKEFELD (1996) konnte zeigen, daß es möglich ist, unter Laborbedingungen häufig in Zuckerrüben vorkommende Unkrautarten zu 68 % richtig computerbildanalytisch zu bestimmen. Beste Ergebnisse wurden mit Unkräutern im Keimblatt-

stadium erzielt. Praxistaugliche Systeme zur Pflanzenbestimmung (z.B. zur Unkrautkontrolle) existieren noch nicht. Selektive Sensoren, wie z.B. das System 'detectspray' oder 'selectspray', erkennen nicht die Gattung oder die Art als solche, sondern können nur Pflanzen und Boden bzw. Hintergrund anhand der Reflexion im roten bis nahen infraroten Wellenlängenbereich voneinander unterscheiden (BILLER 1996, AUDENAERT 1996). Einige Untersuchungen nutzten Farbinformationen zur Trennung von Pflanzen und Hintergrund (siehe z.B. GEORG et al. 1992, MASSEN 1996), andere Textur und Formunterschiede (ZHANG und CHAISATTAPAGON 1995).

Die bisher durchgeführten Untersuchungen wurden überwiegend im sichtbaren Wellenlängenbereich durchgeführt. Aufnahmeobjekte waren CCD-Kameras oder Scanner, neuerdings auch Photokameras mit Digitaleinheit (siehe BURMEISTER 1996). Die Aufnahmen fanden häufig unter artifiziellen Bedingungen statt. Die Merkmalsextraktion erfolgte mit einfachen bildanalytischen Operatoren und Formmerkmalen (z.B. GHAZANFARI und IRUDAYARAJ 1996, VAN DE VOOREN et al. 1991, ZAYAS et al. 1990 u.a. s.o.) oder mit komplexen Globaloperatoren (Hough-Transformation, Fourier-Transformation, Co-occurrence-Matrizen) (siehe WOLFE und SWAMINATHAN 1987, SHEARER und HOLMES 1990, WILHOIT et al. 1990, QUI und SHEARER 1992, TAO et al. 1995b, MOLLER NIELSEN et al. 1995, FRANZ et al. 1995 u.a. s.o.). Zur Datenauswertung kommen in der Regel statistische Ansätze zum Einsatz. Neuere Untersuchungen verwenden auch Fuzzy-Logik oder künstliche neuronale Netzwerke (siehe HOWARTH und SEARCY 1991, BEN-HANAN et al. 1991, LIAO et al. 1993, YANG 1993, DECK et al. 1991, STEINMETZ et al. 1994, NAKANO et al. 1995, SIMONTON und GRAHAM 1996 u.a. s.o.).

### 3. Dendrologische Verfahren und Merkmale der Pflanzenbestimmung

Pflanzen werden allgemein zu systematischen Einheiten zusammengefaßt, die die Verwandtschaft, die durch die gemeinsame Evolution gegeben ist, widerspiegeln sollen (FITSCHEN 1994). Grundlegende Einheit ist die Art, übergeordnete Stufen bilden die Gattung, Familie, Ordnung, Klasse und Abteilung. Die Unterteilung der Art erfolgt bei wildwachsenden Pflanzen in Unterarten, Varietäten und Formen. Im Bereich der kultivierten Pflanzen wird die Art häufig in Sorten unterteilt (vgl. FITSCHEN 1994). Die Unterscheidung von Gehölzen kann durch vegetative und generative Merkmale erfolgen. Wichtige vegetative Merkmale zur Gehölzbestimmung sind die Form, Farbe, Ausprägung und Abwandlungen der Sproßachse sowie die morphologischen Eigenschaften der Blätter, die Blattfolge, die Blattstellung und etwaige Blattmetamorphosen. Eine Bestimmung nach generativen Merkmalen verwendet die Morphologie der Blütenstände oder das Erscheinungsbild der Blüte bei Samenreife (Frucht). Zur Gehölzbestimmung im Winter können die Ausprägungen der Winterknospen verwendet werden (vgl. GODET 1995).

Es existieren unterschiedlich strukturierte und aufgebaute Bestimmungsschlüssel. Bei Verwendung der Gehölzflora von FITSCHEN (1994) wird die zu bestimmende Pflanze zuerst über einen synoptischen Gruppenschlüssel einer von sechs Gattungsgruppen zugeordnet. Hierzu werden die vegetativen Merkmale Blattausbildung (nadelförmig oder anders), Aufbau der Blattspreite (zusammengesetzt oder anders), Blattstellung (gegenständig oder anders) und Feinstruktur des Blattrandes (ganzrandig oder anders) verwendet. Innerhalb der Gruppen erfolgt die genaue Bestimmung der Gattung (z.T. mit Hinweisen auf mögliche Arten) mit weiteren Schlüsseln, die auf stärker differenzierten vegetativen Merkmalen aufbauen. Alternativ kann die Gattung mit einem Früchte- oder Blütenschlüssel bestimmt werden. Die genaue Identifikation der Art erfolgt innerhalb der Gattungen nach vegetativen und generativen Merkmalen. Strichzeichnungen unterstützen die Entscheidungsfindung. Es werden die mitteleuropäische Gehölzflora und wichtige eingeführte Arten (insgesamt über 2000 Arten) beschrieben.

Fitschens Bestimmungsverfahren ist auf die Verwendung differenzierter botanisch morphologischer Merkmale ausgerichtet. Andere Schlüssel nutzen nur die wesentlichen morphologischen Kennzeichen zur Gattungsbestimmung und überlassen die Bestimmung der Art dem

Benutzer, indem Bilder und Detailzeichnungen der unterschiedlichen Arten angeboten werden. MITCHELL und WILKINSON (1982) verfahren nach diesem Prinzip, wobei sie zur Gattungsbestimmung von Laubbäumen fast ausschließlich Blattmerkmale verwenden. Ihr Schlüssel ist von deutlich einfacherer Prägung als der von FITSCHEN (1994). Jedoch werden im Anschluß an die Gattungsbestimmung die einzelnen Arten mit Detailzeichnungen von Blättern, Früchten, Blütenständen, Rinden und Wuchsformen näher dargestellt. Beschreibende Texte runden die Kennzeichnung der einzelnen Arten ab. Zur Gehölzbestimmung im Winter bieten MITCHELL und WILKINSON (1982) zusätzlich einen Schlüssel an, der auf Trieb- und Knospeneigenschaften aufbaut. Insgesamt werden ca. 500 Arten beschrieben.

GODET (1987) kombiniert in seinem Bestimmungsschlüssel morphologisch botanische Blatteigenschaften mit exzellenten Farbphotos. Insgesamt werden über 270 Arten unterschieden. In einem ersten Schritt werden die Gehölze anhand ihrer Belaubung auf fünf Teilschlüssel aufgeteilt (Nadeln, zusammengesetzte Laubblätter, ganze gelappte Laubblätter, ganze ganzrandige Laubblätter, ganze nicht ganzrandige Laubblätter). Innerhalb jedes Teilschlüssels erfolgt die Bestimmung der Gattung und der Art mit Entscheidungsfragen, die ähnlich wie bei MITCHELL und WILKINSON (1982) auf vegetativen Blattmerkmalen aufbauen, jedoch mit Detailphotos unterstützt werden. Zur Absicherung und Überprüfung des Bestimmungsergebnisses existieren Photozusammenstellungen (Blatt- und Zweigphotos) und Merkmalbeschreibungen aller mit dem Schlüssel differenzierbaren Arten. In einem Sonderteil werden von den bedeutendsten freistehenden Laubbäumen entscheidungsunterstützende Photos von Blütenständen, Früchten, Knospen, Rinde, Holz, jahreszeitlich unterschiedlichen Belaubungen und Wuchsformen gezeigt.

Im folgenden wird am Beispiel der Bestimmung von *Quercus robur* die Spezifität der einzelnen Bestimmungsverfahren demonstriert und gegenübergestellt. Es sind jeweils die zur Entscheidung führenden und zu bejahenden Fragen bzw. Aussagen der Schlüssel zeilenweise aufgeführt.

### 1. Bestimmung von *Quercus robur* nach FITSCHEN (1994):

#### Gruppenschlüssel

- keine Nadelgehölze
- Blätter normal ausgebildet
- Blätter einfach

- Blätter wechselständig
  - Blätter nicht ganzrandig
- ==> Gruppe IV

#### Gattungsschlüssel (Gruppe IV)

- Blattrand wellig oder Blatt gelappt oder eingeschnitten
  - Zweige ohne Ranken
  - Blattadern nicht gabelig verzweigt
  - von der Basis der Blattspreite geht nur die Mittelader aus, von der die untersten Seitenadern etwas höher abzweigen
  - Blatt nicht linealisch
  - Zweige ohne umfassende Linie
  - Blattrand eingeschnitten oder gelappt z.T. auch ganzrandig
  - Blattspreite gelappt (Buchten stumpf), Blätter über 6 cm lang
  - Blattspreite jederseits mit mehr als einer Bucht
- ==> 23 mögliche Quercus-Arten

#### Artenschlüssel (Gattung Quercus)

- Blatt fiedrig gelappt, Blatthälfte ± asymmetrisch
  - Blattlappen ohne Granne oder mit sehr kurzen, höchstens 1 mm langen Stachelspitzen
  - Blatt unterseits sehr früh kahl werdend oder nur auf der Mittelader schwach behaart
  - Blatt kleiner, nur an Lohdentr. über 14 cm lang; Borke dunkel, rissig, nicht abblättern
  - Blattstiel 2-8 mm lang, Blatt länglich bis verkehrt eiförmig, meist 5-10 cm lang, 2-6 cm breit, unregelmäßig rund gelappt mit jederseits 3-6 Blattlappen, Basis der Blattspreite geöhrt, Blatt oberseits dunkelgrün, unterseits graugrün, kahl; Früchte 1 bis mehrere, 5-12 cm lang gestielt (!)
- ==> Quercus robur

### 2. Bestimmung von Quercus robur nach MITCHELL und WILKINSON (1982):

#### Bestimmungsschlüssel für Laubbäume im Sommer

- Blatt ungeteilt - sommergrün - selten hart oder dunkel
  - tief gelappt oder gebuchtet, mindestens bis zur Hälfte eingeschnitten
  - viele Lappen an jeder Seite der Mittelrippe
- ==> Gattung Quercus

#### Spezifizierung von 32 Arten der Gattung Quercus

- Quercus robur:
1. Zeichnungen von Blatt, Blüte, Frucht und Wuchsform
  2. Beschreibung:
    - ..... fast ungestielte, aber deutlich geöhrt Blätter ....
    - ..... lang gestielte weibl. Blüten und Früchte .....
- ==> Quercus robur

### 3. Bestimmung von Quercus robur nach GODET (1987):

#### Übersichtsschlüssel (mit Bildern)

- ganze Blätter
  - gelappte Blätter
- ==> Gruppe III

Teilschlüssel (Gruppe III, mit Bildern)

- Laubblätter nicht ahornartig gelappt, sondern mit jeweils jederseits 3-10 Lappen
- Laubblätter mit jederseits mehr als 4 Lappen
- Lappen der Laubblätter nicht gesägt, Laubblätter eichenblattartig gelappt
- Laubblätter mit breiten und stumpfen oder abgerundeten Lappen
- an der Basis jederseits der Hauptader ein kl. Öhrchen und Blattstiel nicht über 7 mm lang

== > Quercus robur

Die aufgeführten Bestimmungen verdeutlichen, daß zahlreiche Blattmerkmale notwendig sind, um Laubgehölze an ihren Blättern zu unterscheiden. Die Merkmale werden innerhalb der Schlüssel differenziert, kombiniert, abgeschwächt oder verstärkt. Numerische Merkmale werden mit *gleich*, *kleiner*, *größer*, *im Bereich von*, *m bis n* oder *ca.* spezifiziert. Je nach Schlüssel werden unterschiedliche Merkmale und Differenzierungen in den Vordergrund gestellt. Abbildung 3.1 verdeutlicht dieses beispielhaft an der Detailierung der Blattrandeigenschaft 'gezähnt' innerhalb des Bestimmungsschlüssels von MITCHELL und WILKINSON (1982). Die anderen Blattrandformen werden in demselben Schlüssel nur schwach differenziert. Aus Abbildung 3.1 wird ersichtlich, welche feine - und für den Pflanzenbestimmer schwierige - morphologische Unterscheidung notwendig ist, um Gehölze an ihren vegetativen Blattmerkmalen zu bestimmen. Abbildung 3.2 faßt die in den drei beschriebenen Bestimmungsschlüsseln verwendeten morphologischen Blatteigenschaften und -ausprägungen zusammen.

<u>Ausprägung der Zähnung:</u>	<u>Anzahl der Zähne</u>	<u>Größe der Zähne</u>
völlig ungezähnt	einige Zähne	sehr kleine Zähne
nicht gezähnt	zahlreiche Zähne	kleine Zähne
ungezähnt	m bis n Zähne	große Zähne
schwach gezähnt		
gezähnt		
spärlich gezähnt		
seicht gezähnt		
undeutlich gezähnt		
winzig gezähnt		
fein gezähnt		
grob gezähnt		
tief gezähnt		
scharf gezähnt		
intensiv gezähnt		
	<u>Anordnung der Zähne:</u>	<u>Besonderheiten der Zähne:</u>
	regelmäßig gezähnt	Zähne mit Borsten
	unregelmäßig gezähnt	Zähne hakenförmig
	Zähne sehr dicht stehend	Zähne dreieckig
	Zähne dicht stehend	Zähne verdickt
	Zähne weit stehend	Zähne hart
		Zähne abgerundet
		Zähne scharf umgebogen
		Zähne ganzrandig

Abb. 3.1: Spezifizierungen der Blattrandeigenschaft *gezähnt* im Bestimmungsschlüssel von MITCHELL und WILKINSON (1982)

<u>Blattstellung</u>	<u>Aufbau der</u>	<u>Form der</u>	<u>Form der</u>
<u>am Zweig:</u>	<u>Spreite:</u>	<u>Spreite:</u>	<u>Basis, Spitze:</u>
wechselständig gegenständig kreuzgegenständig quirlständig wirtelig gescheitelt zweizeilig schraubig	ungeteilt ( einfach) gebuchtet eingeschnitten gelappt 3-lappig 4-lappig 5-lappig zusammengesetzt unpaarig gefiedert paarig gefiedert mehrfach gefiedert gefingert 3-zählig	linealisch länglich schmal schlank lanzettlich vekehrt eilanzettlich eiförmig verkehrt eiförmig elliptisch oval rundlich viereckig breit fächerförmig spatelförmig rautenförmig nierenförmig handförmig	zugespitzt verschmälert ausgerandet ausgezogen abgerundet gestutzt stumpf eingedrückt eingeschnitten geöhrt herzförmig keilförmig pfeilförmig schildförmig
<u>Blattrand-</u> <u>feinstruktur:</u>	<u>Adern-</u> <u>verlauf:</u>	<u>3-D-Eigenschaften</u> <u>von Blatt und Stiel:</u>	<u>Vergleich und An-</u> <u>ordnung von Blatt-</u> <u>hälften und -lappen:</u>
ganzrandig engerollt umgebogen wellig gekerbt gezähnt gesägt doppelt gesägt eingeschnitten gewimpert stachelig dornig	unverzweigt parallelnervig bogenläufig fächerförmig fiedernervig handnervig gabelig	dick dünn gewölbt gedreht kantig abgeflacht	symmetrisch asymmetrisch schief radial gleichartig unterschiedlich auseinanderklaffend
<u>numerische Merkmale:</u>		<u>sonstige spezielle Merkmale:</u>	
Anzahl von Blättchen, Adern und Blattlappen Länge und Breite der Blattspreite und Blattlappen Länge zu Breite der Blattspreite Blattstiellänge		Behaarung Drüsenbesatz Farbe Geschmack, Geruch Blattsaft Mark Winterbelaubung	
<u>Verwendete Blattunterteilungen:</u>			
Blattspreite, Blattgrund, Blattspitze, Blattstiel Blättchen, Blatthälfte, Blattlappen Blattunterseite, Blattoberseite			

Abb. 3.2: Wesentliche Blattmerkmale und Eigenschaften in den Bestimmungsschlüssel von FITSCHEN (1994), MITCHELL und WILKINSON (1982) und GODET (1987)

## 4. Grundlagen der Computerbildanalyse und Definitionen

### 4.1 Darstellung und Codierung von Bildinformationen

Die computergerechte Darstellung bzw. Modellierung von Bildern kann mit unterschiedlichen Ansätzen erfolgen. Bei einer Pixelgrafik (Bitmap) liegt das Bild in einzelnen Bildpunkten vor, welche jeweils die Helligkeit oder Farbkomponente an einer bestimmten Bildstelle repräsentieren. Durch die Verwendung mehrerer Bitmaps für ein und dasselbe Bild lassen sich unterschiedliche Farbräume spezifizieren. Es gilt:

$$\mathbf{A}_k = \begin{bmatrix} a_{1,1} & a_{1,2} & \dots & a_{1,m} \\ a_{2,1} & a_{2,2} & \dots & a_{2,m} \\ \dots & \dots & \dots & \dots \\ a_{n,1} & a_{n,2} & \dots & a_{n,m} \end{bmatrix}$$

$\mathbf{A}_k$ : Bitmap der k-ten Bildkomponente

$a_{i,j}$ : Helligkeit, Farbintensität oder Farbsättigung o.ä. an der Stelle  $i,j$

$n, m$ : Maximale Zeilen- bzw. Spaltenanzahl des Bildes

Obwohl ein Bitmap die physikalischen Gegebenheiten der visuellen Information gut wiedergibt, ist der direkt in weiteren Analyseprozessen nutzbare Informationsgehalt solcher Bilder relativ gering (diese Tatsache führt häufig zu Fehlinterpretationen: eine hohe Auflösung wird mit einem hohen, direkt im Computer nutzbaren Informationsgehalt des Bildes gleichgesetzt). Bitmaps werden vielfach mit digitalen Eingabegeräten (Scanner, CCD-Kamera oder digitale Photokamera) oder mit Zeichenprogrammen erzeugt. Eine direkte Verarbeitung mit Bildverarbeitungsprogrammen ist möglich (Rotation, Skalierung, Addition, Subtraktion etc.), jedoch ist insbesondere bei Operationen, die eine Maßstabsveränderung des Bildes verursachen, evtl. mit Stör-Effekten (Weglassen oder Hinzufügen von wesentlichen Bildinhalten) zu rechnen.

Ein spezielles Bitmap ist das Binärbild, welches lediglich Pixel zweier möglicher Zustandsformen beinhaltet. Die Bilder können leicht in Punktmengen überführt werden, die die Zugehörigkeit einer Ortskoordinate zu einer bestimmten Gruppe oder Eigenschaft dokumentiert. Die Verarbeitung solcher Bilder kann im Gegensatz zur Matrixoperation bei Bitmaps als Mengenoperation auf Punktmengen verstanden werden. Trotz ihrer geringeren Informa-

tionsmenge gegenüber nichtbinären Bitmaps stellt die Punktmengendarstellung inhaltliche Zusammenhänge eines Bildes gut dar, da Bilder in bestimmte Regionen und Flächen aufgeteilt werden. Zur kompakteren Darstellung wird oft die Lauflängenkodierung verwendet, bei der mehrere Punkte zu Geraden zusammengefaßt werden. Werden z.B. die Nummern der Zeile ( $k$ ), der Startspalte ( $l$ ) und der Endspalte ( $j$ ) des jeweiligen Geradenstückes zur Codierung verwendet, ergibt sich für  $n$  Geradenstücke folgende Gleichung (links Lauflängencodierung, rechts Koordinaten der Punkte der binären Punktmenge):

$$\{(k_1 \cdot l_1, j_1), (k_2 \cdot l_2, j_2), \dots, (k_n \cdot l_n, j_n)\} = \begin{array}{l} \{(k_1 \cdot l_1), (k_1 \cdot l_1 + 1), (k_1 \cdot l_1 + 2), \dots, (k_1 \cdot j_1), \\ (k_2 \cdot l_2), (k_2 \cdot l_2 + 1), (k_2 \cdot l_2 + 2), \dots, (k_2 \cdot j_2), \\ \vdots \\ (k_n \cdot l_n), (k_n \cdot l_n + 1), (k_n \cdot l_n + 2), \dots, (k_n \cdot j_n)\} \end{array} \quad (4.1.1)$$

Steht die Umrißlinie  $V$  einer Region, Fläche oder Punktmenge im Vordergrund des Interesses, kann eine sogenannte Kettencodierung als Funktion  $\diamond_K(V)$  erfolgen. Ausgehend von einem Startpunkt wird dabei die Konturlinie der darzustellenden Region mit einem Code nachverfolgt, der die Orientierung der einzelnen Pixel zueinander berücksichtigt. Es gilt:

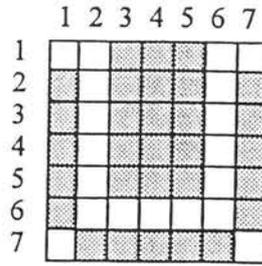
$$\diamond_K(\{\mathbf{v}_1, \mathbf{v}_2, \mathbf{v}_3, \dots, \mathbf{v}_n\}) = (t_1, t_2, t_3, \dots, t_{n-1}) \quad \text{mit} \quad (4.1.2)$$

$$t_i = \frac{4\gamma_i}{\pi}$$

$\gamma_i$ : Winkel [rad] im Uhrzeigersinn zwischen einer Bezugslinie ausgehend vom Punkt  $\mathbf{v}_i$  und einer Linie zwischen den Punkten  $\mathbf{v}_i$  und  $\mathbf{v}_{i+1}$

$\diamond_K$ : Kettencode (von  $V$ )

Als Ausrichtung der Bezugslinie wird in der Regel die Senkrechte nach oben oder die Waagerechte nach rechts gewählt. Ferner muß zur vollständigen Codierung der Kettenlinie noch der Startpunkt im Code vorhanden sein.



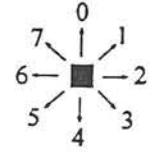
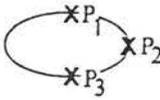
Codierungsverfahren	Codierungsprinzip	Code		Einsatzschwerpunkt
		Objekt 1	Objekt 2	
Pixelorientierte Codierung (Pixelgrafik)	Punktcodierung mit Grau- oder Farbstufen  z.B.: schwarz = 0 weiß = 1	1 1 0 0 0 1 1 0 1 0 0 0 1 0 0 1 1 1 1 1 0 1 0 0 0 0 0 1		Darstellung von Binär-, Grauwert- und Farbbildern
Laufängencodierung	Sehnenfolgen mit Sehnenlage*, Sehnenanfang**, Sehnenende**  * = Zeilennummer ** = Spaltennummer	1 3 5, 2 3 5 3 3 5, 4 3 5 5 3 5	2 1 1, 2 7 7 3 1 1, 3 7 7 4 1 1, 4 7 7 5 1 1, 5 7 7 6 1 1, 6 7 7 7 2 6	Darstellung von Regionen und Flächen
Ketten-codierung	Linienverfolgung mit Richtungscode  	2 2 4 4 4 4 6 6 0 0 0 0  Startkoordinaten: (1,3)	4 4 4 4 3 2 2 2 2 1 0 0 0 0  Startkoordinaten: (2,1)	Darstellung von Konturlinien und Umrissen
Codierung mit geometrischen Grundelementen (Vektorgrafik)	Vektorgleichung mit Stützstellen  z.B. Ellipse: 	Ellipsengleichung mit $P_1 = \begin{pmatrix} 1 \\ 4 \end{pmatrix}$ $P_2 = \begin{pmatrix} 3 \\ 5 \end{pmatrix}$ $P_3 = \begin{pmatrix} 5 \\ 4 \end{pmatrix}$	Geradengleichungen (Polygonzug) mit $\begin{pmatrix} 2 \\ 1 \end{pmatrix} \begin{pmatrix} 6 \\ 1 \end{pmatrix} \begin{pmatrix} 7 \\ 2 \end{pmatrix}$ $\begin{pmatrix} 7 \\ 6 \end{pmatrix} \begin{pmatrix} 6 \\ 7 \end{pmatrix} \begin{pmatrix} 2 \\ 7 \end{pmatrix}$	Darstellung von Grafikelementen und technischen Zeichnungen

Abb. 4.1.1: Methoden zur Codierung von Bildern und Grafiken an einem Beispiel

Bisher beschriebene Bild- bzw. Objektcodierungen geben außer der Pixelanzahl nur relativ wenig Informationen über die Beschaffenheit oder Form einzelner Bildbestandteile. Aus diesem Grund werden Objekte bzw. Bestandteile eines Bildes, wenn möglich, in Form von Vektorgrafiken codiert. Bildelemente werden hierbei aus geometrischen Elementen mit ihren dazugehörigen Stützstellen zusammengesetzt, die beliebig verschoben, vergrößert, verkleinert, gedreht, gestreckt oder anderweitig berechnet werden können. Üblicherweise werden als Grundelemente Geraden, Ellipsen und kubische Splines verwendet. Typische Einsatzbereiche sind CAD-Programme, technische oder dreidimensionale grafische Zeichnungen.

Abbildung 4.1.1 verdeutlicht die unterschiedlichen Ansätze der Bilddarstellung. Detaillierte Beschreibungen finden sich bei ABMAYR (1994) und PAVLIDIS (1992).

#### **4.2 Allgemeine Vorgehensweise der Computerbildverarbeitung**

Die Computerbildverarbeitung oder auch Computerbildanalyse beschäftigt sich mit der rechnergestützten bzw. automatischen Auswertung und Weiterverarbeitung digitaler Bildinformationen. Es wird versucht, mit Filterverfahren und Bildmanipulationen eine möglichst weite Umwandlung des Pixelcodes in Richtung vektororientierte und auf geometrischen Formen basierende Grafik zu realisieren (Bildaufbereitung). Anschließend werden die Bilder auf repräsentative Merkmale verdichtet, die mehrdimensionale Merkmalsvektoren ergeben. Sollen mehrere Bilder miteinander verglichen werden oder sollen aus zahlreichen Bildvarianten Gruppenzugehörigkeiten gewonnen werden, ist es notwendig, den resultierenden Merkmalsraum noch weiter auf eine eindimensionale Größe zu verdichten (Datenauswertung oder Dateninterpretation). Zur Modellierung und Durchführung dieser Verdichtungsprozesse werden unterschiedlichste Verfahren und Ansätze eingesetzt. Abbildung 4.2.1 stellt die Einordnung des Prozesses in einen Gesamtprozeß und die schrittweise Durchführung der Computerbildverarbeitung bildlich dar.

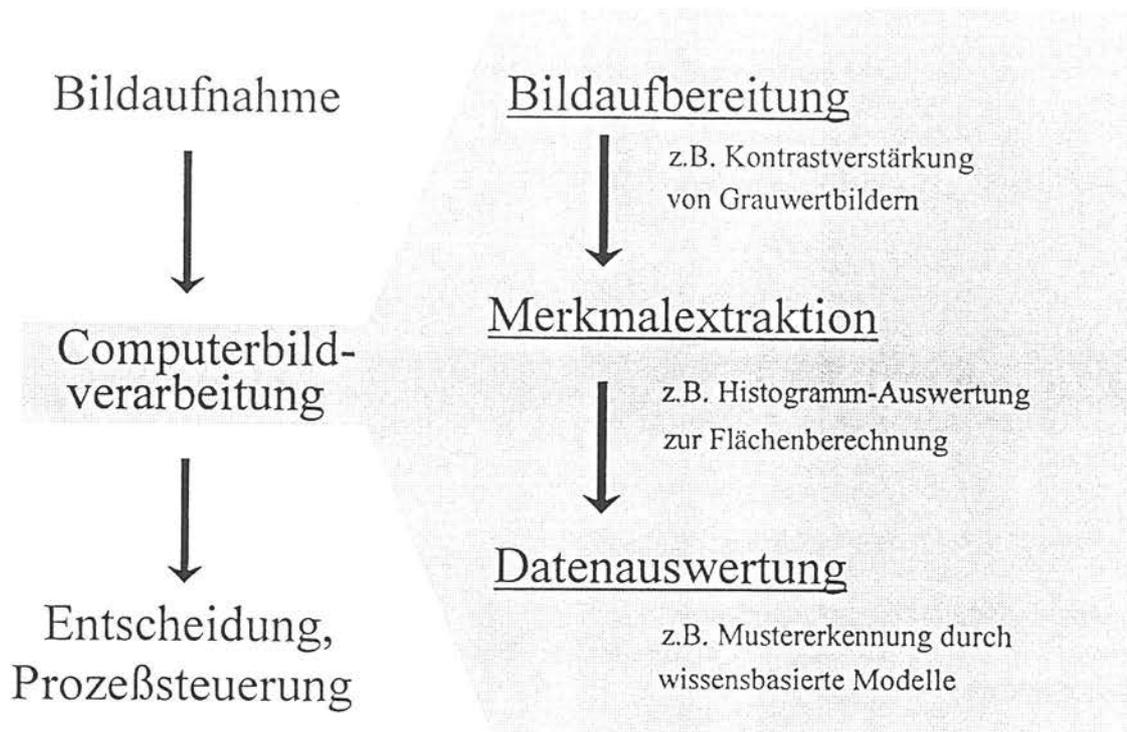


Abbildung 4.2.1 : Einordnung der Computerbildverarbeitung in den Gesamtprozeß

### 4.3 Bildbearbeitung und -manipulation

#### 4.3.1 Bearbeitung und Manipulation von Grauwertmatrizen

Zur Bearbeitung von Grauwertbildern kommen spezielle Verfahren und Operatoren zum Einsatz. Punktoperatoren verändern den Grauwert eines Pixels in Abhängigkeit vom Ausgangsgrauwert, d.h. ohne direkte Berücksichtigung der Nachbarpunkte. Verfügbare Verfahren lassen sich zum großen Teil als Grauwertspreizung zusammenfassen. Es gilt:

$$\Psi_B(\mathbf{A}, \mathbf{s}, \mathbf{r}) = \mathbf{C} \quad \text{mit} \quad (4.3.1)$$

$$c_{ij} = \begin{cases} r_1 & \text{falls } a_{ij} \leq s_1 \\ r_2 & \text{falls } a_{ij} > s_2 \\ r_1 + \frac{(r_2 - r_1)(a_{ij} - s_1)}{s_2 - s_1} & \text{sonst} \end{cases}$$

**A:** Eingabebild (Grauwertmatrix)

**s:** Schwellenwertvektor

**r:** Zuordnungsvektor

$\Psi_B$ : Binarisierung, Grauwertspreizung, Schwellenwertfilterung (von **A** mit **s** und **r**)

Man erkennt, daß bei geeigneter Wahl des Schwellenwert- und Zuordnungsvektors eine Binarisierung oder Schwellenwertfilterung oder eine Helligkeits- und Kontrastveränderung bestimmter Grauwertbereiche möglich ist. Zur Wahl des geeigneten Schwellenwertes wird normalerweise die Häufigkeitsverteilung der Grauwerte des Gesamtbildes (Histogramm) eingesetzt (siehe u.a. LOW 1991). Abbildung 4.3.1 zeigt an einem eingescannten Blatt von *Platanus x acerifolia* den Einsatz eines Schwellenwertfilters zur Binarisierung und Hintergrundtrennung eines Grauwertbildes. Es ist zu beachten, daß das Ergebnisbild nicht nur aus dem Blatt, sondern auch aus den kleinen Punktstörungen besteht.

Neben der Grauwertspreizung haben Operatoren eine große Bedeutung, die die Summe der gewichteten Pixelgrauwerte der lokalen Umgebung des zu bearbeitenden Pixels berücksichtigen (lokale Operatoren). Nach ABMAYR (1994) können sie als Faltungen definiert werden. Die Filtercharakteristik wird geprägt durch die Dimension und die Elemente der Filter- bzw. Faltungsmatrizen. Für die Verrechnung der Filtermatrizen mit dem Grauwertbild gilt:

$$\Psi_F(\mathbf{A}, \mathbf{B}_{(m_1, m_2)}) = \mathbf{C} \quad \text{mit} \quad (4.3.2)$$

$$c_{kl} = \lambda_1 \sum_{i=1}^{m_1} \sum_{j=1}^{m_2} b_{ij} a_{k-n_1+i, l-n_2+j} + \lambda_2 \quad \text{mit}$$

$$n_i = \max \left( \left\{ x \mid x \leq \frac{m_i + 1}{2} \right\}, x \in \mathbb{IN}_0 \right)$$

**A:** Eingabebild (Grauwertmatrix)

**B:** Filter- oder Faltungsmatrix

$\lambda_i$ : Skalierungskonstanten

$\Psi_F$ : diskrete Faltung (von **A** mit **B**)

Abbildung 4.3.2 stellt die wichtigsten Filter- bzw. Faltungsmatrizen und die resultierenden Operationsbezeichner dar.

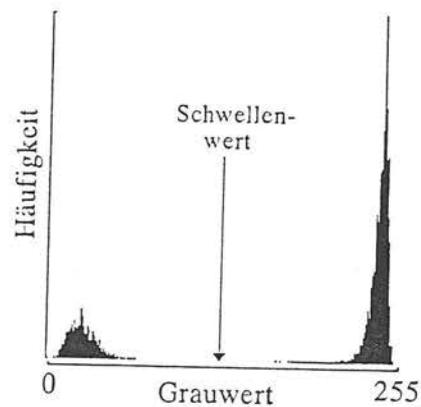
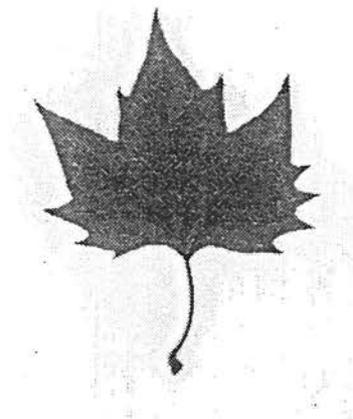


Abb. 4.3.1: Einsatz eines Schwellenwertfilters zur Hintergrunderkennung von Grauwertbildern

Oben links: gescanntes Ausgangsbild

Oben rechts: Histogramm der Grauwerte

Unten links: Binarisiertes Ergebnisbild

Matrix	Faltungsergebnis	Endergebnis der Filterung	Filterbezeichnung
$\begin{pmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{pmatrix}$	<b>C</b>	<b>C</b>	Mittelwertfilter
$\begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix}$	<b>C'</b>	<b>C</b>	
$\begin{pmatrix} 0 & 1 \\ -1 & 0 \end{pmatrix}$	<b>C''</b>	mit z.B. $c_{ij} = \max( c'_{ij} ,  c''_{ij} )$	Robertsfilter
$\begin{pmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{pmatrix}$	<b>C'</b>	<b>C</b>	
$\begin{pmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{pmatrix}$	<b>C''</b>	mit z.B. $c_{ij} = \sqrt{c'_{ij}{}^2 + c''_{ij}{}^2}$	Sobelfilter
$\begin{pmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{pmatrix}$	<b>C</b>	<b>C</b>	Laplacefilter

Abb. 4.3.2: Grauwertfilter und die zugehörigen Filter- bzw. Faltungsmatrizen

Wie aus der Symmetrie der Matrizen hervorgeht, wirken einige Filter richtungsunabhängig, wie z.B. der grauwertglättende Mittelwertfilter oder der aufgrund der stark unterschiedlichen Matrixelemente kontrastverstärkende Laplacefilter. Gradientenoperatoren (z.B. Roberts- oder Sobelfilter) heben besonders Kanten in bestimmte Richtungen hervor. Die so entstehenden Richtungsbilder können mit weiteren Verfahren (siehe Spalte 3 der Abb. 4.3.2) zu einem Ergebnisbild verdichtet werden. Abbildung 4.3.3 demonstriert den Einsatz des Robertsfilters zur Kantendetektion an einem gescannten Blatt von *Platanus x acerifolia*.

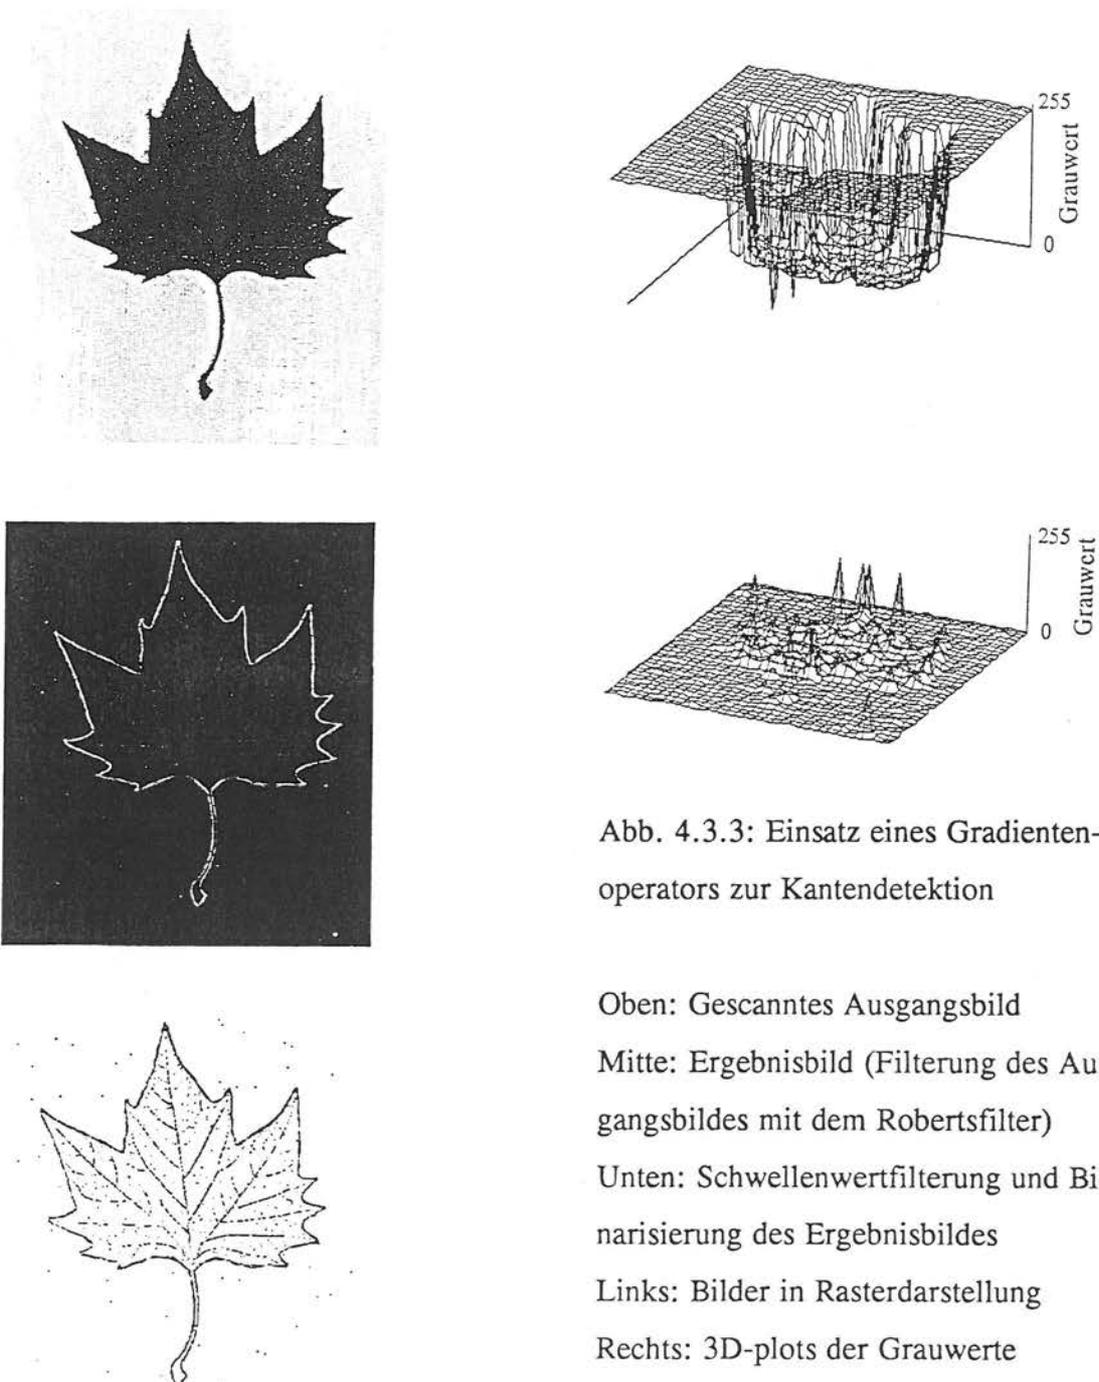


Abb. 4.3.3: Einsatz eines Gradientenoperators zur Kantendetektion

Oben: Gescanntes Ausgangsbild

Mitte: Ergebnisbild (Filterung des Ausgangsbildes mit dem Robertsfilter)

Unten: Schwellenwertfilterung und Binarisierung des Ergebnisbildes

Links: Bilder in Rasterdarstellung

Rechts: 3D-plots der Grauwerte

Neben den beschriebenen Operatoren werden auch globale Operatoren, die die gesamte Grauwertcharakteristik des Bildes verwenden, eingesetzt. Wichtigste Verfahren sind die Hough-Transformation und die Fouriertransformation. Die Hough-Transformation nutzt die Umwandlung der Bilddaten von kartesischen Koordinaten in Polarkoordinaten um Geradenstücke oder Formen zu erkennen. Mit Hilfe der Fouriertransformationen werden periodische Zusammenhänge des Bildes analysiert. Da diese Verfahren innerhalb dieser Arbeit nur von untergeordneter Bedeutung sind, wird auf eine weitere Beschreibung verzichtet. Näheres findet sich z.B. bei ZAMPERONI (1991) oder PAVLIDIS (1982).

### 4.3.2 Bearbeitung und Manipulation von Punktmenge

Bisher vorgestellte Operatoren wurden auf Grauwertmatrizen mit Hilfe von Filtermatrizen definiert. Da binäre Grauwertmatrizen als Punktmenge beschrieben werden können, lassen sich auch Bearbeitungsverfahren als Punktmengeoperatoren definieren. Formel (4.3.3) stellt die Generierung einer Punktmenge aus einer Grauwertmatrix (entspricht der Binarisierung aus Formel (4.3.1)) dar:

$$\Omega_G(\mathbf{A}, \mathbf{s}) = \left\{ \mathbf{h} \mid s_1 \leq a_{h_1 h_2} \leq s_2 \right\} = H \quad (4.3.3)$$

$\mathbf{A}$ : Eingabebild (Grauwertmatrix)

$\mathbf{s}$ : Schwellenwertvektor

$H$ : Ergebnisflächen (Punktmenge)

$\Omega_G$ : Generierung (von  $H$  aus  $\mathbf{A}$  mit  $\mathbf{s}$ )

Mit Hilfe affiner Transformationen lassen sich Punktflächen skalieren, verschieben oder drehen (vgl. Formel (4.3.5) bis (4.3.6)). Drehungen um beliebige Winkel und Skalierungen erfordern Interpolationsverfahren, die das Ziel haben, den Bildzusammenhang in der binären Bildmatrix aufrechtzuerhalten (zu Interpolationsverfahren siehe ABMAYR 1994). Es gilt:

$$\Omega_R(R) = H \quad (4.3.4)$$

$R$ : Eingabemenge (Elemente  $\in \mathbb{R}^2$ )

$H$ : Ergebnisfläche (Punkte  $\in \mathbb{Z}^2$ )

$\Omega_R$ : Rundung bzw. Interpolation der Koordinaten unter Verwendung der Nachbarpunkte

$$\Omega_A(H, \mathbf{r}, \gamma) = \Omega_R \left\{ \left\{ \mathbf{v} \mid \begin{pmatrix} v_1 \\ v_2 \\ 1 \end{pmatrix} = \begin{pmatrix} \cos\gamma & \sin\gamma & r_1 \\ -\sin\gamma & \cos\gamma & r_2 \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} h_1 \\ h_2 \\ 1 \end{pmatrix}, \mathbf{h} \in H \right\} \right\} \quad (4.3.5)$$

$H$ : Eingabefläche (Punktmenge)

$\mathbf{r}$ : Verschiebungsvektor

$\gamma$ : Drehwinkel

$\Omega_A$ : affine Abbildung (Verschiebung und Drehung von  $H$  mit  $\mathbf{r}$  und  $\gamma$ )

$$\Omega_M(H, \mathbf{r}) = \Omega_R \left( \left\{ \mathbf{v} \mid v_1 = r_1 h_1, v_2 = r_2 h_2, \mathbf{h} \in H \right\} \right) \quad (4.3.6)$$

$H$ : Eingabefläche (Punktmenge)

$\mathbf{r}$ : Skalierungsvektor

$\Omega_M$ : affine Abbildung (Maßstabsveränderung, Skalierung von  $H$  mit  $\mathbf{r}$ )

Wichtigste Operatoren der Binärbildverarbeitung sind Verfahren, die die Ausgangsdaten unter Verwendung strukturierender Elemente bearbeiten und manipulieren. Die Verfahren werden allgemein unter dem Begriff morphologische Filter oder mathematische Morphologie zusammengefaßt. Sie werden überwiegend zur Manipulation von Binärbildern (Punkt Mengen) eingesetzt und gehen auf Arbeiten von SERRA (1982) zurück.

Wird eine Punktmenge durch Schnittmengenbildungen der Ausgangsfläche mit allen möglichen Verschiebungen eines strukturierenden Elementes (im folgenden als Verschiebungsmaske bezeichnet) verringert, bezeichnet man die resultierende Operation als Erosion. Bildet man die Vereinigungsmenge anstatt der Schnittmenge, bezeichnet man diese flächenergänzende Operation als Dilation. Formel (4.3.7) und (4.3.9) sind die exakten Definitionen auf der Basis von Mengenoperationen (siehe hierzu auch HARALICK et al. 1987). Formel (4.3.8) und (4.3.10) stellen Erosion und Dilation unter Verwendung fest definierter Verschiebungsmasken dar.

$$\Omega_E(H, V) = \bigcap_{-\mathbf{w} \in V} \Omega_A(H, \mathbf{w}, 0) \quad (4.3.7)$$

$H$ : Eingabefläche (Punktmenge)

$V$ : Verschiebungsmaske (Punktmenge)

$\Omega_E$ : Erosion (von  $H$  mit  $V$ )

$$\Omega_E^k(H) = \Omega_E(H, V_k) \quad \text{mit} \quad (4.3.8)$$

$V_4 = \{(0,0), (-1,0), (0,-1), (1,0), (0,1)\} = 4\text{-er Nachbarschaft}$  oder

$V_8 = \{(i,j) \mid i, j \in \{-1, 0, 1\}\} = 8\text{-er Nachbarschaft}$

$H$ : Eingabefläche (Punktmenge)

$k$ : Index der verwendeten Maske

$\Omega_E^k$ : Erosion (von  $H$ ) mit 4-er oder 8-er Nachbarschaftsmaske

$$\Omega_D(H, V) = \bigcup_{-\mathbf{w} \in V} \Omega_A(H, \mathbf{w}, 0) \quad (4.3.9)$$

$H$ : Eingabefläche (Punktmenge)

$V$ : Verschiebungsmaske (Punktmenge)

$\Omega_D$ : Dilation (von  $H$  mit  $V$ )

$$\Omega_D^k(H) = \Omega_D(H, V_k) \quad \text{mit} \quad V_4 \text{ oder } V_8 \text{ vgl. Formel (4.3.8)} \quad (4.3.10)$$

$H$ : Eingabefläche (Punktmenge)

$k$ : Index der verwendeten Maske

$\Omega_D^k$ : Dilation (von  $H$ ) mit 4-er oder 8-er Nachbarschaftsmaske

Verknüpft man die Erosion mit der Dilation, wird das Verfahren als Opening bezeichnet. Wird die Ausgangsmenge zuerst dilatiert und dann erodiert, nennt man die resultierende Operation Closing (siehe SERRA 1982). Wichtiges Kriterium beim Einsatz morphologischer Filter ist die richtige Auswahl der Verschiebungsmasken (Größe und Form).

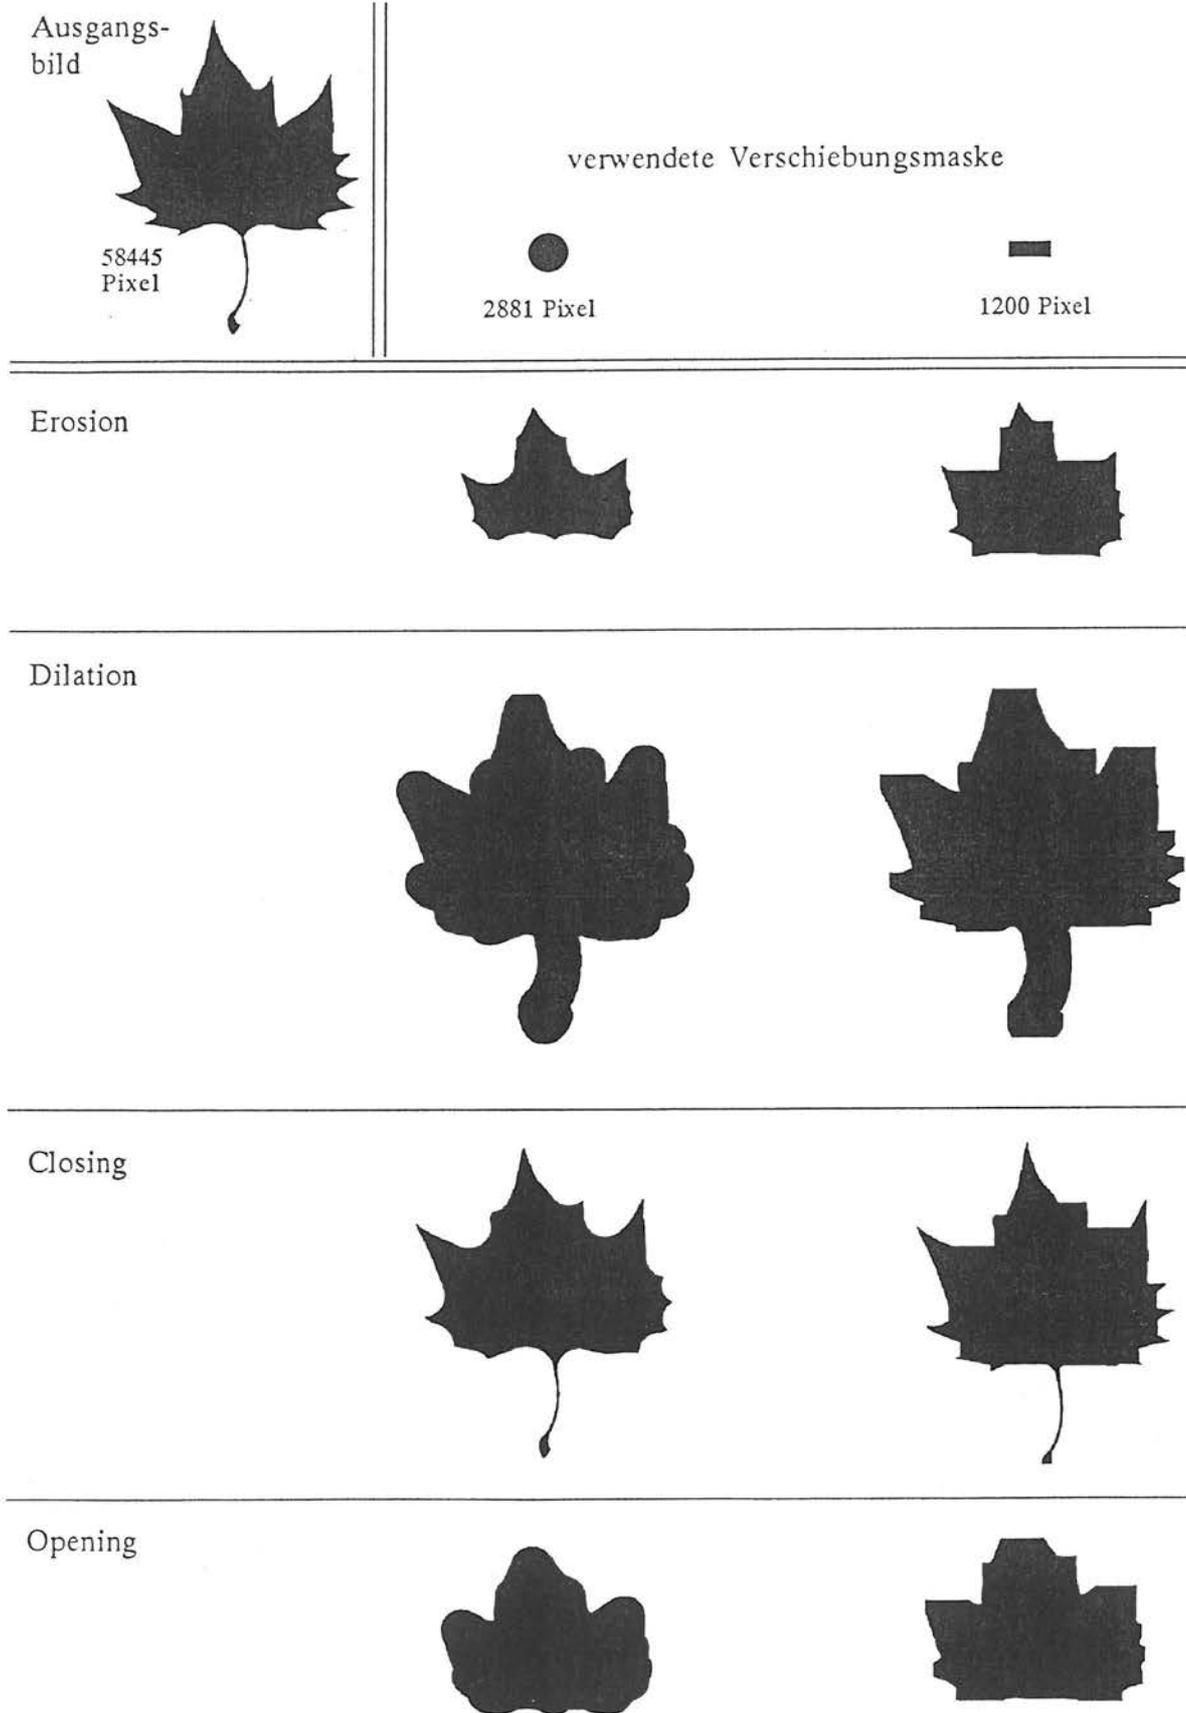


Abb. 4.3.4: Grundlegende morphologische Operatoren an einem Beispiel

Abbildung 4.3.4 verdeutlicht dies an der morphologischen Bearbeitung mit Hilfe des Erosion-, Dilation-, Opening- und Closingoperators der Blattfläche des binären Ergebnisbildes aus Abbildung 4.3.1. Während Erosion und Dilation je nach verwendeter Verschiebungsmaske zur Abschwächung der gesamten Formspezifität des Ausgangsobjektes führen, beeinflussen die Hintereinanderschaltungen der beiden Verfahren bestimmte Merkmale des Ausgangsblattes überproportional. Man sieht, daß der Closing-Operator zu einer Auffüllung von Einbuchtungen und Löchern führt, während Opening Ausbuchtungen und Spitzen abrundet bzw. nivelliert (siehe hierzu auch Beispiele von MARAGOS 1989).

Morphologische Operatoren lassen sich mehrmals hintereinander iterativ ausführen. Abbildung 4.3.5 stellt die iterative Verwendung der Erosion und der Dilation an einem Beispiel mit unterschiedlichen Verschiebungsmasken und Iterationstiefen dar. Im obersten Bild besteht die Ergebnismenge aus dem Stiel und den Blattspitzen. Das nächste Ergebnisbild besteht nur aus dem eingekürzten Stiel. Beim Bild im dritten Abschnitt ist der Stiel an beiden Enden eingekürzt und das unterste Ergebnisbild entspricht dem Ergebnisbild in Abschnitt 2. In allen Fällen wurden dieselben Operationen durchgeführt, jeweils mit unterschiedlichen Parametern. Man erkennt, daß es möglich ist, bei geeigneter Wahl der Parameter gezielt Bildelemente zu separieren (hier den Stiel).

Hinsichtlich der iterativen Verwendung morphologischer Operatoren gilt für weitere Ausführungen folgende Kurzschreibweise:

$$\overbrace{\Omega_{\beta}(H, \dots)}^n = \overbrace{\Omega_{\beta}(\overbrace{\Omega_{\beta}(\dots \Omega_{\beta}(\Omega_{\beta}(H, \dots), \dots)}^{n-\text{mal}}), \dots)}^{n-\text{mal}} \quad (4.3.11)$$

$n$ : Anzahl Iterationsschritte

$H$ : Startfläche im ersten Iterationsschritt (Punktmenge)

$\dots$ : restliche Operationseingabeparameter

$\overbrace{\Omega_{\beta}}^n$ :  $n$ -fach iterative, morphologische Operation

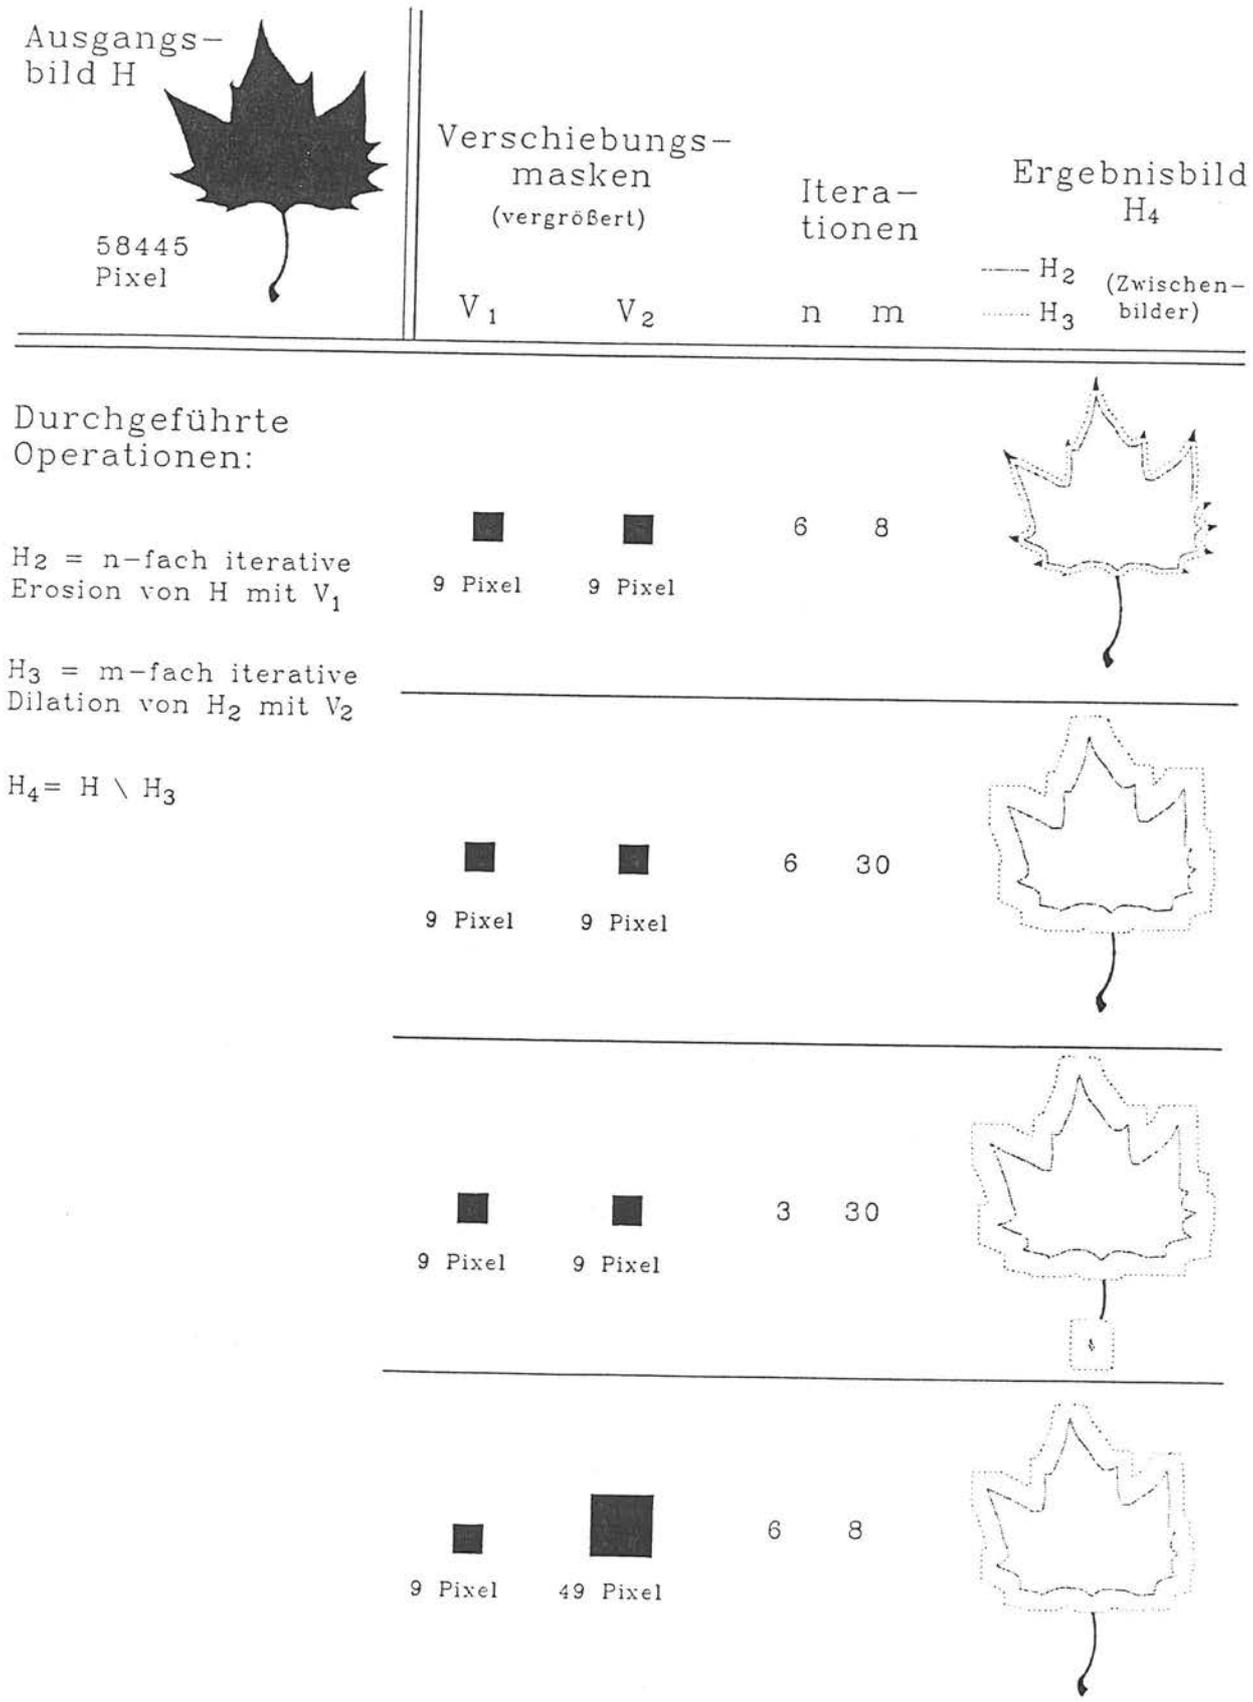


Abb. 4.3.5: Iterativer Einsatz morphologischer Operatoren mit unterschiedlichen Masken

Mit Hilfe der Dilation eines Punktes einer zu bearbeitenden Ausgangsfläche und anschließender Schnittmengenbildung mit der Ausgangsfläche oder mit einer mit der Ausgangsfläche in Verbindung stehenden Fläche (Formel (4.3.12)) lassen sich weitere wichtige morphologische Operationen definieren:

$$\Omega_P(H, W) = \Omega_D^8(H) \cap W \quad (4.3.12)$$

$H$ : Eingabefläche bzw. Startpunkt (Punktmenge)

$W$ : Schnittfläche (Punktmenge)

$\Omega_P$ : Punktdilation (von  $H$  in  $W$ )

$$\Omega_T(H) = \left\{ W_{i=1, 2, 3, \dots} \left| W_i = \overbrace{\Omega_P \left( \left\{ \mathbf{h} \in \left( H \setminus \bigcup_{j < i} W_j \right) \right\}, H \right)}^n \right. \right\} \quad (4.3.13)$$

$H$ : Eingabefläche (Punktmenge)

$\mathbf{h}$ : Startpunkt

$n$ : Anzahl Iterationen, bis keine Flächenänderung mehr stattfindet

$\Omega_T$ : iterative Teilregionenbildung (von  $H$  mit 8-er Nachbarschaftsmaske)

$$\Omega_F(H) = \neg W \quad \text{mit} \quad W = \overbrace{\Omega_P \left( G, \neg H \cup G \right)}^n \quad (4.3.14)$$

$H$ : Eingabefläche (Punktmenge)

$G$ : geschlossene Umrandung von  $H \cup \neg H$

$n$ : Anzahl Iterationen, bis keine Flächenänderung mehr stattfindet

$\Omega_F$ : iteratives Füllen (von  $H$  mit 8-er Nachbarschaftsmaske)

Zum einen können aus einer Punktmenge je nach Wahl der Verschiebungsmaske (hier als Nachbarschaftsmaske bezeichnet) mehrere Teilmengen gebildet werden, die nicht miteinander verbunden sind (bzw. nicht mit der Nachbarschaftsmaske verbunden werden können). Diese als iterative Teilregionenbildung in Formel (4.3.13) beschriebene Operation hat im

weiteren Verlauf der Arbeit große Bedeutung und kann quasi als Umkehrung der Vereinigung der Teilmengen bezeichnet werden. Abbildung 4.3.6 zeigt die mit Formel (4.3.13) getrennten Teilregionen des Ergebnisses aus Abbildung 4.3.1. Zum anderen kann ein Auffüllen von Hohlfächen in Bildobjekten erfolgen (iteratives Füllen, Formel (4.3.14)), indem eine Hintergrundregion durch Punktdilation auf den gesamten Bildhintergrund erweitert wird. Das Komplement der Hintergrundmenge ergibt am Ende die gefüllten Objekte des Ausgangsbildes.

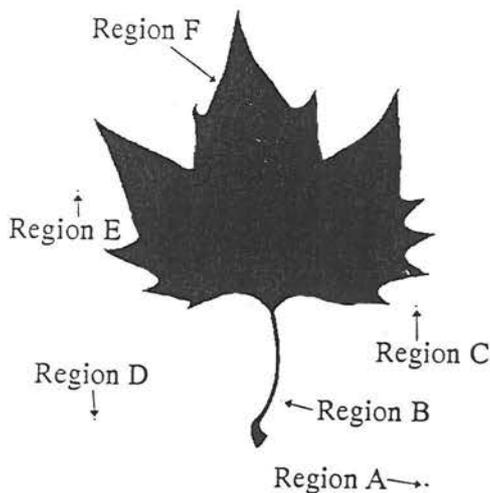


Abb. 4.3.6.: Beispiel für iteratives Teilen einer Punktmenge

Objekte können mit Hilfe der Hintereinanderschaltung iterativer morphologischer Operatoren auf Strukturelemente (z.B. Rand, Strichzeichnung) reduziert werden, die nur 1 Pixel breit sind. Während der Rand einer Punktmenge relativ einfach durch Erosion mit 4-er Nachbarschaftsmaske (vgl. Formel (4.3.8)) und anschließende Differenzbildung zwischen Ausgangsobjekt und Dilationsergebnis errechnet werden kann (vgl. ECKSTEIN 1993), existieren demgegenüber auch etliche Verfahren, bei denen mehrere Verschiebungsmasken iterativ eingesetzt werden.

Abbildung 4.3.7 zeigt die Verdünnung einer Punktmenge zu einer Strichzeichnung. Ausgangsbasis ist die größte Teilregion des Ergebnisbildes aus Abbildung 4.3.6. Es kommen Verschiebungsmasken zum Einsatz, die durch Drehung um jeweils 45 Grad unterschiedliche Struktureigenschaften des Ausgangsobjektes erfassen und auf einen Pixel verdichten. Nach 75 Iterationsschritten ist das Ausgangsobjekt vollständig in eine Strichzeichnung umgewandelt. Das Verfahren wird allgemein als Skelettierung und die Strichzeichnung als Skelett bezeichnet. Es existieren unterschiedliche Ansätze, die auch unterschiedliche Skelette er-

zeugen (siehe JANG und CHIN (1990)). Aus Recheneffizienzgründen wird im folgenden ausschließlich das von ECKHARDT (1988) beschriebene und von ECKSTEIN (1993) codierte Verfahren der Skelettbildung eingesetzt. Eine weitere Reduzierung der Strichzeichnung auf die Kreuzungs- oder Endpunkte des Skelettes kann durch Erosionen mit den entsprechenden Filtermasken (mögliche Verzweigungsarten oder Endpunkte), erfolgen.

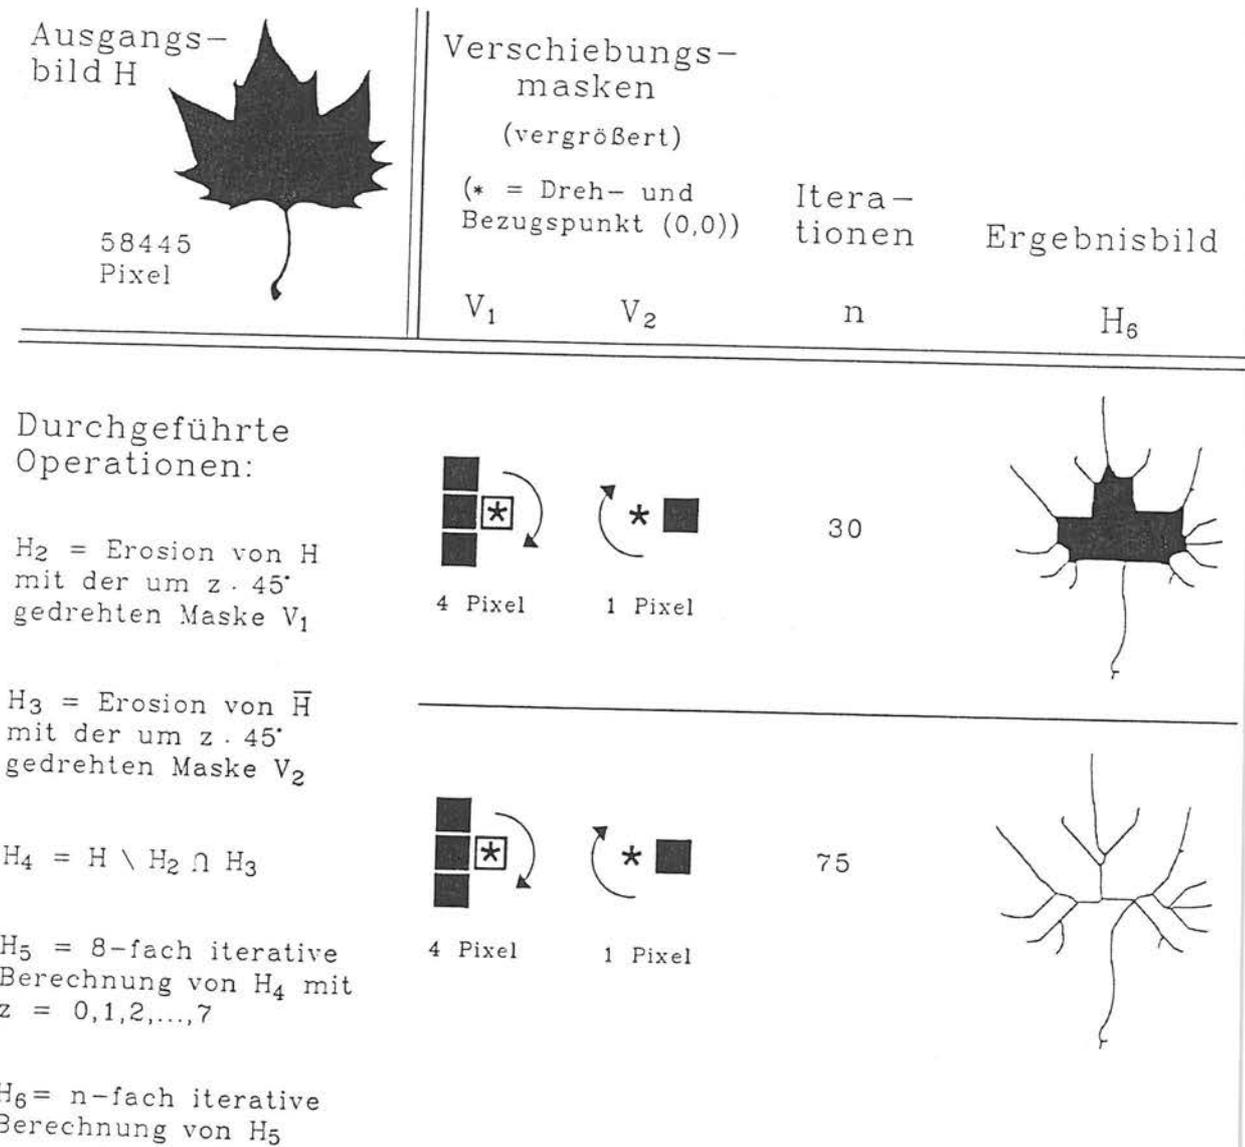


Abbildung 4.3.7: Beispiel der Skelettbildung mit morphologischen Operatoren

Im weiteren gelten folgende Definitionen:

$$\Omega_{V_\beta}(H) = \text{iterative morphologische Verdünnungsoperationen,} \quad (4.3.15)$$

die  $H$  auf 1 Pixel breite Strukturelemente reduzieren,  $\beta \in \{a, k, r, s\}$  mit

$V_a$ : Reduzierung auf Skelettanfangs- und -endpunkte

$V_k$ : Reduzierung auf Skelettkreuzungspunkte

$V_r$ : Reduzierung auf den Rand

$V_s$ : Reduzierung auf eine Strichzeichnung (Skelett)

$H$ : Eingabefläche (Punktmenge)

Neben morphologisch orientierten Bildmanipulationen werden häufig auch Verfahren zur Bildverarbeitung eingesetzt, die auf geometrische oder geometrisch orientierte Grundformen aufbauen und z.T. mit morphologischen Operationen ermittelt werden können. Berechnungsverfahren und -algorithmen finden sich z.B. bei ROTH (1996) oder ECKSTEIN (1993). Mit Formel (4.3.16) wird der geometrische Schwerpunkt eines Objektes bestimmt. Formel (4.3.17) beschreibt die Bildung der konvexen Hülle einer Punktmenge, das heißt, die Umhüllung des Objektes ohne Einbuchtungen. Sie ist für die weiteren Ausführungen von großer Bedeutung. Besteht die Eingangsregion lediglich aus zwei Punkten, liefert Formel (4.3.17) die Punktmenge, die die Gerade zwischen den beiden Punkten beschreibt.

$$\Phi_S(H) = \Omega_R \left( \left\{ \frac{1}{n} \sum_{i=1}^n \mathbf{h}_i \right\} \right) \quad \text{mit} \quad H = \{ \mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_n \} \quad (4.3.16)$$

$H$ : Eingabefläche (Punktmenge)

$\Phi_S$ : geometrischer Schwerpunkt (von  $H$ )

$$\Phi_H(H) = \Omega_R \left( \left\{ \mathbf{v} \mid \mathbf{v} = \sum_i \lambda_i \mathbf{h}_i, 0 \leq \lambda_i \leq 1, \sum_i \lambda_i = 1 \right\} \right) \quad (4.3.17)$$

$H$ : Eingabefläche (Punktmenge)

$\Phi_H$ : konvexe Hülle (von  $H$ )

Die Bildung weiterer wichtiger geometrischer Grundformen wie Rechteck, Quadrat, Ellipse und Kreis auf der Basis von Punktfolgen beschreiben die folgenden Gleichungen:

$$\Phi_R(\mathbf{r}, \mathbf{s}, \gamma) = \Omega_A(\{\mathbf{h} \mid |h_1| \leq r_1, |h_2| \leq r_2\}, \mathbf{s}, \gamma) \quad (4.3.18)$$

$$\Phi_E(\mathbf{r}, \mathbf{s}, \gamma) = \Omega_A\left(\left\{\mathbf{h} \mid h_1^2 \leq \frac{r_1^2 r_2^2 - r_1^2 h_2^2}{r_2^2}, h_2^2 \leq \frac{r_1^2 r_2^2 - r_2^2 h_1^2}{r_1^2}\right\}, \mathbf{s}, \gamma\right) \quad (4.3.19)$$

$$\Phi_Q(r_1, \mathbf{s}, \gamma) = \Phi_R(\mathbf{r}, \mathbf{s}, \gamma) \quad \text{mit } r_1 = r_2, \gamma \text{ beliebig} \quad (4.4.20)$$

$$\Phi_K(r_1, \mathbf{s}) = \Phi_E(\mathbf{r}, \mathbf{s}, \gamma) \quad \text{mit } r_1 = r_2, \gamma \text{ beliebig} \quad (4.3.21)$$

Für (4.3.18) bis (4.3.21) gilt:

$\mathbf{r}$ : Halbmesser (Länge in Richtung der Ausrichtung, Breite),  $\mathbf{r} = (r_1, r_2)$

$\mathbf{s}$ : Mittelpunkt

$\gamma$ : Ausrichtung des Objektes (Drehwinkel)

$\Phi_E$ : Ellipse

$\Phi_K$ : Kreis

$\Phi_Q$ : Quadrat

$\Phi_R$ : Rechteck

Die geometrischen Grundformen werden variabel eingesetzt, das heißt, daß manchmal das Objekt anhand der notwendigen Parameter genau beschrieben wird, manchmal aber einzelne Parameterangaben offen bleiben, so daß Objektfolgen entstehen. Für die weiteren Ausführungen und für die in (4.3.18) bis (4.3.21) beschriebenen Grundformen gelten nachfolgende Definitionen und Berechnungen ( $\beta \in \{E, K, Q, R\}$ ):

$\Phi_\beta(\mathbf{r}, \mathbf{s}, \gamma)$ : eindeutig definierte geometrische Grundform  $\beta$  (siehe oben)

$$\begin{aligned} \Phi_{\beta}(\gamma): & \quad \text{geometr. Grundform } \beta \text{ mit Ausrichtung } \gamma \text{ (Höhe und Breite beliebig)} \\ \Phi_{\beta} = \Phi_{\beta}(\ ): & \quad \text{allgemeine geometr. Grundform } \beta \text{ (belieb. Rechteck, Ellipse etc.)} \end{aligned} \quad (4.3.22)$$

Wichtige variable geometrische Grundformen sind kleinste umschließende Rechtecke oder Ellipsen, die Vergleichsobjekte vollständig abdecken und den kleinsten Flächeninhalt aller möglichen umschließenden Objekte haben. Auf der Basis von Punktmenge können solche Flächen wie folgt beschrieben werden.

$$\Phi^{\beta}(H, \dots) = V \quad \text{mit} \quad (4.3.23)$$

$$V = \Phi_{\beta}(\dots), V \supseteq H, \Gamma_P(V) = \min(\{\Gamma_P(W) \mid W = \Phi_{\beta}(\dots), W \supseteq H\})$$

H:	Grundfläche, (Punktmenge)
...:	übrige Eingabeparameter
$\beta$ :	Grundformenindex $\in \{R, O, E, K\}$
$\Phi^{\beta}(H, \gamma)$ :	kleinste, $H$ umschließende Grundform $\beta$ mit Ausrichtung $\gamma$
$\Phi^{\beta}(H, \mathbf{s})$ :	kleinste, $H$ umschließende Grundform $\beta$ mit Mittelpunkt $\mathbf{s}$
$\Phi^{\beta}(H)$ :	kleinste, $H$ umschließ. Grundform $\beta$ (belieb. Rechteck, Ellipse etc.)

Berechnungsverfahren finden sich bei ROTH (1996), ECKSTEIN (1993) oder PAVLIDIS (1982).

#### 4.4 Merkmalextraktion aus Grauwertbildern und Punktmengen

Zur Bildauswertung werden in der Regel Grauwertmatrizen oder Punktmengen auf numerische Merkmale verdichtet. Wichtigstes Charakterisierungsmerkmal einer Grauwertmatrix ist die Häufigkeitsverteilung seiner Grauwerte (Histogramm). Sie wird vornehmlich zur Bestimmung der Schwellenwertvektoren bei der Grauwertspreizung eingesetzt (siehe Abschnitt 4.3.1), sie kann aber auch direkt zur Kontrastverstärkung und Bildverbesserung des Bildes genutzt werden (Grauwertäqualisation, vgl. ABMAYR 1994). Darüberhinaus werden die Häufigkeitsverteilungen von Grauwertdifferenzen benachbarter Pixel benutzt, um Struktureigenschaften von Bildern zu identifizieren (Einsatz von Co-occurencematrizen, vgl. ABMAYR 1994).

Wichtige Merkmale von Binärbildern sind Pixelflächen und Abmessungen der zu analysierenden Punktmengen. Die Pixelfläche eines Objektes ergibt sich direkt aus dem Histogramm der Binärwertverteilungen bzw. aus der Anzahl der in einer Menge oder Teilmenge enthaltenen Pixel (Formel (4.4.1)). Analog dazu kann die Anzahl an Teilflächen einer Regionenmenge mit Formel (4.4.2) definiert werden. Die Bestimmung von Punkt- bzw. Flächenabständen oder Strecken kann nicht direkt anhand der Pixelfläche des auf den Rand verdünnten Objektes durchgeführt werden, vielmehr muß eine Gewichtung der diagonal benachbarten Pixel erfolgen. Unter Verwendung der euklidischen Metrik  $d_E$  (Definition und Erklärung in Kapitel 4.5.2) ergibt sich der Abstand zweier Punktmengen nach Formel (4.4.3). Um Rechenlaufzeiten gering zu halten, können auch anstatt der gesamten Punktmengen nur die Konturlinien der Eingaberegionen in Gleichung (4.4.3) eingehen (vgl. auch ECKSTEIN 1993). Die Länge der Konturlinie und der Umfang eines Objektes werden mit Gleichung (4.4.4) beschrieben. Es gilt:

$$\Gamma_P(H) = \begin{cases} 0 & \text{falls } H = \{\} \\ n & \text{sonst} \end{cases} \quad \text{mit } H = \{h_1, h_2, h_3, \dots, h_n\} \quad (4.4.1)$$

$H$ : Eingabefläche (Punktmenge)

$\Gamma_P$ : Pixelfläche, Anzahl Pixel (von  $H$ )

$$\Gamma_T(\mathbf{G}) = \begin{cases} 0 & \text{falls } \mathbf{G} = \{\} \\ n & \text{sonst} \end{cases} \quad \text{mit } \mathbf{G} = \{G_1, G_2, G_3, \dots, G_n\} \quad (4.4.2)$$

$\mathbf{G}$ : Eingabeflächen (Menge von Punktmenge)

$\Gamma_T$ : Anzahl an Teilflächen (in  $\mathbf{G}$ )

$$\Gamma_A(H, V) = \min_{i,j} (d_E(\mathbf{h}_i, \mathbf{v}_j)) \quad (4.4.3)$$

$H, V$ : Eingabefläche (Punktmenge oder Punkt)

$d_E$ : euklidischer Abstand (siehe Kapitel 4.5.2)

$\Gamma_A$ : euklidischer Abstand (zwischen  $H$  und  $V$ )

$$\Gamma_U(H) = \sum_i d_E(\mathbf{v}_i, \mathbf{w}_i) \quad \text{mit} \quad (4.4.4)$$

$$\Omega_{V_r}(H) = V = W \quad \text{und} \quad \mathbf{w}_i = \mathbf{v}_i + \mathbf{g} \quad \text{mit} \quad g_j \in \{-1, 0, 1\}$$

$H$ : Eingabeflächen (Punktmenge)

$d_E$ : euklidischer Abstand (siehe Kapitel 4.5.2)

$\Gamma_U$ : Umfang oder Länge der Konturlinie (von  $H$ )

Neben aufgeführten Flächen- und Längenmerkmalen spielen besonders noch Radien, Halbmesser und Ausrichtungen der kleinsten umschließenden geometrischen Objekte (Rechteck, Quadrat, Ellipse, Kreis) eine wichtige Rolle zur Merkmalsbildung. Sie lassen sich direkt aus den Parametern der erzeugten Objekte ableiten oder können durch Abstandsmessung zwischen Schwerpunkt und der Schnittmenge zwischen einer - entsprechend der Ausrichtung des Objektes verlaufenden - Geraden und der Konturlinie des geometrischen Objektes gebildet werden. Die Definitionen lauten:

$$\Gamma_{R_i}(H) = r_i \quad \text{mit} \quad \Phi^R(H, \mathbf{r}, \gamma) = \Phi^R(H, \gamma) = \Phi^R(H) \quad (4.4.5)$$

$H$ : Eingabefläche (Punktmenge)

$\Gamma_{R_i}$ : halbe Länge ( $i = 1$  oder ohne Index) bzw. halbe Breite ( $i = 2$ , Breite  $\leq$  Länge) bzw. Halbmesser oder Radius des Objektes  $H$  (gemessen mit kleinstem umschließenden Rechteck)

$$\Gamma_W(H) = \gamma \quad \text{mit} \quad \Phi^R(H, \gamma) = \Phi^R(H) \quad (4.4.6)$$

$H$ : Eingabefläche (Punktmenge)

$\Gamma_W$ : Ausrichtungswinkel des Objektes  $H$  (gemessen mit der Ausrichtung des kleinsten umschließenden Rechteckes in Längsrichtung)

Besonders häufig werden größenunabhängige Merkmale zur Klassifikation eingesetzt, die aus dem Verhältnis einer Ausgangsfläche zu einer geometrischen Grundformfläche gebildet werden. Wichtige Maßzahl in diesem Zusammenhang ist die Konvexität (ECKSTEIN 1993) eines Objektes. Es gilt:

$$\Gamma_H(H) = \frac{\Gamma_P(H)}{\Gamma_P(\Omega_H(H))} \quad (4.4.7)$$

$H$ : Eingabefläche (Punktmenge)

$\Gamma_H$ : Konvexität (von  $H$ )

Prinzipiell lassen sich noch sehr viele ähnlich ausgerichtete Verhältnismaßzahlen bilden. Besondere Bedeutung innerhalb dieser Arbeit haben noch die Rundheit, bei der die Objektfläche ins Verhältnis zu einer Kreisfläche gesetzt wird und die Kompaktheit, bei der die Konturlänge Verwendung findet. Die Berechnungsformeln werden direkt an den entsprechenden Stellen angegeben (Kapitel 5.3.3 und 5.3.4). Ferner können Formeigenschaften von Objekten auch mit Flächenmomenten beschrieben werden. Weitere Möglichkeiten und in den verschiedenen Anwendungsfällen eingesetzte Merkmalsgrößen finden sich bei YONEKAWA (1996), RATH (1996c) oder ECKSTEIN (1993).

## 4.5 Datenauswertung zur Identifikation und Klassifikation

### 4.5.1 Allgemeine Einteilung

Zur Auswertung und Weiterverarbeitung der erzeugten Merkmalvektoren muß ein Modell erstellt werden, welches die Zuordnung eines unbekanntes Merkmalvektors zu einer bekannten Klasse ermöglicht. Die eingesetzten Verfahren lassen sich in drei Grundansätze unterteilen:

- statistische Verfahren
- wissensbasierte Systeme
- künstliche neuronale Netzwerke

Die Übergänge zwischen den einzelnen Verfahrensgruppen sind fließend. Ebenso könnten auch andere Aufteilungen erfolgen, da z.B. statistische Verfahren in ihrer Anwendung fast immer auch einen wissensbasierten oder inhaltlich orientierten Anteil aufweisen. Ferner erzeugen neuronale Netze ihre Modellparameter häufig nach streng statistischen Prinzipien; genauso werden wissensbasierte Regelsysteme gewöhnlich nicht ohne statistische Informationen erstellt. Aufgrund der im Bereich der Computerbildverarbeitung verfügbaren Literatur scheint die oben aufgeführte Unterteilung sinnvoll.

### 4.5.2 Statistische Verfahren

Statistische Verfahren analysieren die vorhandenen Daten mit einer abhängigen Klassifikationsvariablen (Gruppenzugehörigkeit) und mit Merkmalvariablen, anhand derer die Gruppen getrennt werden sollen. Sie werden als Diskriminanzanalysen bezeichnet (vgl. SCHUEMER et al. 1990) und unterscheiden sich aufgrund ihrer nicht metrischen, abhängigen Klassifikationsvariable von anderen statistischen Verfahren wie der Clusteranalyse, Faktor- oder Hauptkomponentenanalyse oder Regressionsanalyse (siehe Abb. 4.5.1).

Wichtige Basisgrößen bei der Durchführung von diskriminanzanalytischen Berechnungen sind Distanzmaße, die die mehrdimensionalen Merkmalvektoren in numerische Beziehung zueinander setzen und somit Aussagen über die numerische Ähnlichkeit von Vektoren erlauben. Wichtige Distanzmaße sind die Minkowski-Metriken und die Mahalanobis-Distanzen (vgl. STEINHAUSEN und LANGER 1977). Die als Minkowski-Metriken (oder auch als  $L_z$ -Distanzen) bezeichneten Distanzmaße ergeben sich aus:

$$d_z(\mathbf{x}, \mathbf{y}) = \sqrt[z]{\sum_{i=1}^m |x_i - y_i|^z} \quad \text{speziell: } d_E(\mathbf{x}, \mathbf{y}) = d_2(\mathbf{x}, \mathbf{y}) \quad (4.5.1)$$

$\mathbf{x}, \mathbf{y}$ : Eingabevektoren der Dimension  $m$

$d_z$ : Minkowski-z-Metrik (zwischen  $\mathbf{x}$  und  $\mathbf{y}$ )

$d_E$ : Euklidischer Abstand (zwischen  $\mathbf{x}$  und  $\mathbf{y}$ )

In Formel 4.5.1 ist die Minkowski-2-Metrik hervorgehoben. Sie wird sehr häufig verwendet und wird als euklidische Distanz oder euklidischer Abstand bezeichnet. Wesentliche Eigenschaften des euklidischen Abstandes ergeben sich direkt aus Formel 4.5.1:

- Große und kleine Distanzen einzelner Vektorkomponenten werden unterschiedlich gewichtet: Große Abstände fallen stärker ins Gewicht als kleine.
- Der Euklidische Abstand ist nicht skaleninvariant. Das heißt, daß alle Vektorkomponenten für den Einsatz des Distanzmaßes normiert oder mit vergleichbaren Merkmalseinheiten ausgestattet sein müssen.
- Es erfolgt keine Berücksichtigung etwaiger Korrelationen der Vektorkomponenten. Bei Verwendung korrelierter Variablen führt dies zu einer Überbetonung der entsprechenden Werte.

Werden empirische Abhängigkeiten der Merkmale untereinander genutzt, wird häufig die Mahalanobis-Distanz verwendet. Sie wird auch als generalisierte Distanz bezeichnet und spielt bei der Analyse quantitativer Daten eine große Rolle (STEINHAUSEN und LANGER 1977):

$$d_{MS}(\mathbf{x}, \mathbf{y}) = \sqrt{(\mathbf{x} - \mathbf{y})^T \mathbf{S}^{-1} (\mathbf{x} - \mathbf{y})} \quad (4.5.2)$$

$\mathbf{x}, \mathbf{y}$ : Eingabevektoren

$\mathbf{S}$ : empirische Kovarianzmatrix

$d_{MS}$ : Mahalanobis-Abstand (zwischen  $\mathbf{x}$  und  $\mathbf{y}$ ) unter Verwendung von  $\mathbf{S}$

Durch Verwendung der Invertierten der Kovarianzmatrix (die die empirischen Abhängigkeiten der einzelnen Merkmale untereinander widerspiegelt) ist die Mahalanobis-Distanz ein universell einsetzbares Distanzmaß und überwindet insbesondere die Skaleninvarianz und die fehlende empirische Auswertung der Ausgangsdaten beim Einsatz der euklidischen Distanz. Entscheidend ist jedoch, mit welchen Ausgangsvektoren die eingesetzte Kovarianzmatrix berechnet wird und wie das Berechnungsverfahren durchgeführt werden kann, wenn die Invertierte z.B. aufgrund vieler korrelierender Variablen nicht bestimmbar ist (siehe hierzu STEINHAUSEN und LANGER 1977 oder BOCK 1974).

Statistische Testverfahren, die nichts über die Verteilung in den Grundgesamtheiten voraussetzen, heißen parameterfreie Verfahren. Analog dazu setzen parametrische Tests eine bestimmte Verteilung (meistens Normalverteilung) der Ausgangswerte voraus (BRONSTEIN und SEMENDJAJEW 1987). Geht man von dieser Klassifizierungssystematik aus, können parametrische und parameterfreie Verfahren zur Diskriminanzanalyse unterschieden werden.

Parametrische Verfahren trennen Datensätze anhand von Diskriminanzfunktionen, die aus einem Lerndatensatz gewonnen werden und auf die zu analysierenden Testdatensätze angewendet werden. SAS (1994) beschreibt zwei Verfahren auf der Basis der quadrierten Mahalanobis-Distanz zwischen Testvektor und Gruppenmittelwertvektor. Unter der Bedingung, daß die a-priori-Wahrscheinlichkeit der Zugehörigkeit zu allen Gruppen gleich ist, gelten je nach verwendeter Kovarianzmatrix folgende Diskriminanzfunktionen:

$$f_{d_1}(\mathbf{x}, i) = d_{\mathbf{M}\mathbf{S}}^2(\mathbf{x}, \bar{\mathbf{y}}_i) \quad \text{oder} \quad (4.5.3)$$

$$f_{d_2}(\mathbf{x}, i) = d_{\mathbf{M}\mathbf{S}_i}^2(\mathbf{x}, \bar{\mathbf{y}}_i) + \ln(\det \mathbf{S}_i) \quad (4.5.4)$$

$\mathbf{x}$ : Eingabe-, Testvektor

$i$ : Zu testende Gruppe

$\bar{\mathbf{y}}_i$ : Mittelwertvektor der Gruppe  $i$

$\mathbf{S}_i$ : Innerhalb-der-Gruppen-Kovarianzmatrix der Gruppe  $i$  (des Lerndatensatzes)

$\mathbf{S}$ : Gesamtkovarianzmatrix (des gesamten Lerndatensatzes)

$f_{d_1}$  : Diskriminanzfunktion mit gepoolter Kovarianzmatrix (lineare Diskrimination)

$f_{d_2}$  : Diskriminanzfunktion mit gruppenspezifischer Kovarianzmatrix (quadratische Diskrimination)

Die Diskriminanzfunktion (4.5.3) bzw. (4.5.4) wird für jede Gruppe mit dem Testvektor berechnet. Anschließend wird die Gruppe mit dem kleinsten Diskriminanzwert dem Testvektor als Lösung zugeordnet. Es wird deutlich, daß zur Bildung der Diskriminanzwerte der Merkmalverteilung der gesamten Lerndatensatzes verwendet wird.

Ist der Lerndatensatz so klein, daß keine gesicherte Aussagen über die Merkmalsverteilung gemacht werden kann oder ist die Merkmalsverteilung des Lerndatensatzes nicht normalverteilt, sollten parameterfreie Diskriminanzverfahren eingesetzt werden, da sonst der Einsatz von normalerweise trennschärferen parametrischen Verfahren zu fehlerhaften Ergebnissen führen kann.

Eine parameterfreie Diskriminanzanalyse liefert die nearest-neighbor-Diskriminierung (engl. auch nearest-neighbour-Diskr.), bei der der Testvektor der Gruppe zugeordnet wird, zu dessen Merkmalvektor er den geringsten Abstand hat. Gewöhnlich wird der euklidische Abstand als Distanzmaß verwendet, obwohl die Mahalanobisdistanz z.T. bessere Ergebnisse liefert (SARUNAS und JAIN 1991). Werden mehrere Vergleichsvektoren des Lerndatensatzes zur Diskriminierung herangezogen, spricht man allgemein von  $k$ -nearest-neighbor-Verfahren (Trennung durch durchschnittliche Abstandsbildung unter Verwendung der  $k$  Merkmalsvektoren) (vgl. SCHUEMER et al. 1990). Auf das in dieser Arbeit konkret behandelte Thema bezogen bedeutet das, daß ein unbekanntes Blatt entweder der Gruppe des am ähnlichsten erscheinenden Blattes zugeordnet wird oder es werden die  $k$  ähnlichsten Blätter des Lerndatensatzes verwendet, um die am häufigsten vertretene Gruppe zu bestimmen. Je nach verwendetem Distanzmaß können die resultierenden Merkmale der  $k$ -ähnlichsten Blätter auch noch unterschiedlich skaliert und zusammen auf die angebotene Testblätter der Gruppe bezogen werden (vgl. SAS 1994). Natürlich ist es auch möglich, den Vergleich mit den Mittelwertvektoren der einzelnen Gruppen anzustellen. Dies würde im vorliegenden Fall einem Vergleich mit einem künstlichen, die Gruppe repräsentierenden Durchschnittsblatt entsprechen.

Neben der nearest-neighbor-Diskriminierung finden sich in zahlreichen Tools und statistischen Werkzeugen auch noch Verfahren, die die Klassifizierung mit Hilfe der Beschreibung der zu einer Gruppe gehörenden Vektoren mit Hyperquadern (ECKSTEIN 1993) oder die Suche und Bestimmung der Gruppenzugehörigkeit mit mehrdimensionalen Ellipsoiden im Merkmalraums (kernel-method) (SAS 1994) durchführen.

Weiterhin werden zur Datentrennung auch Merkmale linear-additiv zu kanonischen Variablen zusammengefaßt. Die Komponenten des resultierenden Vektors  $\mathbf{x}$  ergeben sich zu:

$$\mathbf{x} = (x_1, x_2, x_3, \dots, x_m) \quad \text{mit} \quad (4.5.5)$$

$$x_i = \sum_{k=0}^n \lambda_{ki} \varphi_k, \quad \varphi_0 = 1$$

$x_i$ :  $i$ -te kanonische Variable, Funktionswert der  $i$ -ten Linearkombination

$\lambda_{ki}$ :  $k$ -tes Gewicht der  $i$ -ten Linearkombination

$\varphi_k$ :  $k$ -tes Merkmal

$m$ : Anzahl verwendeter Linearkombinationen

$n$ : Anzahl der Merkmale

Die Gewichtung jedes Merkmals erfolgt so, daß die resultierende kanonische Variable ein Maximum der Variation zwischen den einzelnen Gruppen erklärt bzw. daß das Verhältnis der Streuung zwischen den Gruppen zu der Streuung in den Gruppen maximal wird. Werden mehrere Linearkombinationen gebildet, erzeugt die erste den höchsten Erklärungsanteil und die letzte den geringsten Erklärungsanteil zur Trennung der Gruppen, da immer nur auf die verbleibende Reststreuung maximiert wird. Werden weniger kanonische Variablen gebildet, als Merkmale vorhanden sind, führt dieses zur Verdichtung des Merkmalsraumes. Nähere Angaben insbesondere zur Durchführung der Koeffizientenbildung der Linearkombinationen finden sich bei BACKHAUS et al. (1990).

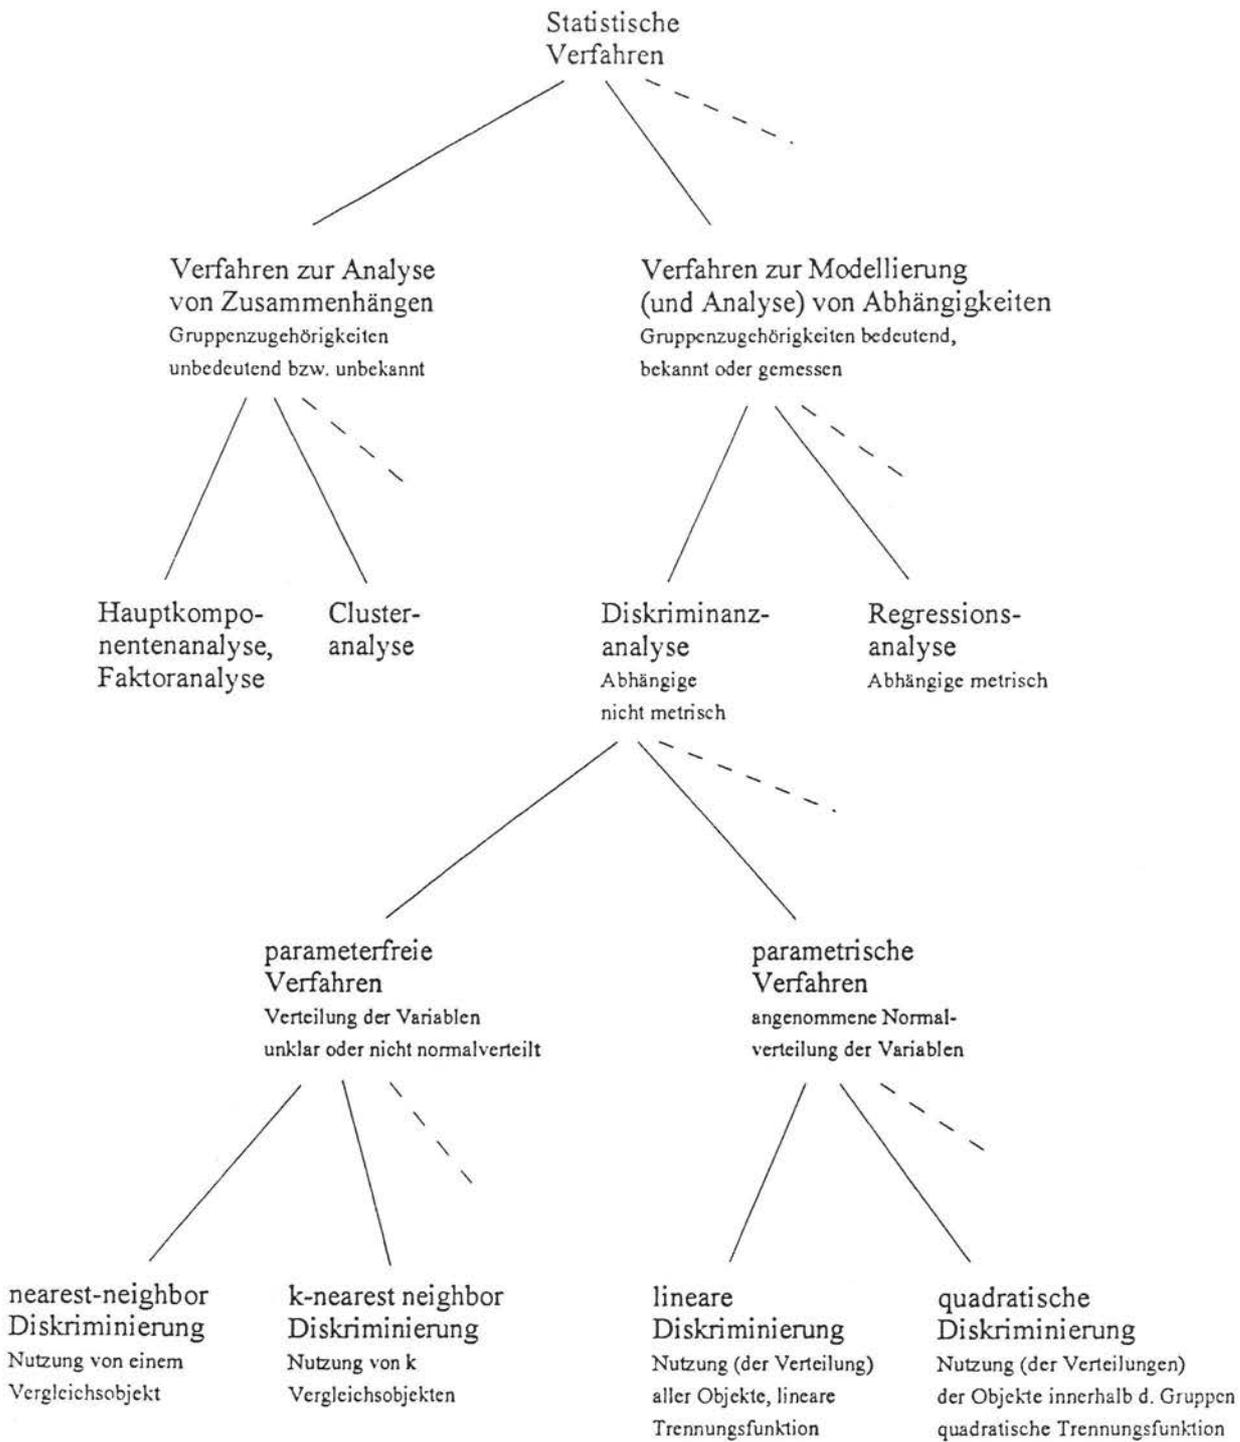
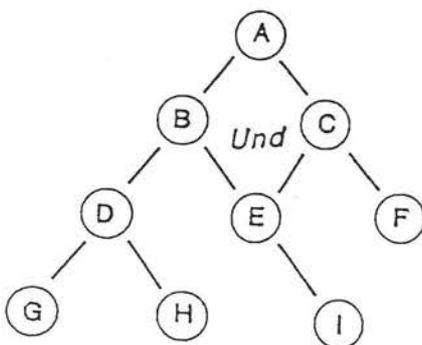


Abb. 4.5.1: Einsatz und Unterteilung statistischer Klassifikationsverfahren (vgl. STEINHAUSEN und LANGER 1977, SCHUEMER et al. 1990 und SAS 1994)

### 4.5.3 Wissensbasierte Systeme und Fuzzy-Logik

Stehen nicht die statistisch-empirischen Zusammenhänge der vorliegenden Datensätze im Vordergrund des Modellansatzes, sondern wird der Schwerpunkt auf die inhaltlichen, logischen Abhängigkeiten gelegt, können wissensbasierte Systeme zur Bildinterpretation bzw. Datenverdichtung zum Einsatz kommen (Beispiele siehe NIEMANN 1985 oder PULITI und TASCINI 1993). Ein wesentliches Kriterium wissensbasierter Systeme ist die Trennung eines allgemeinen Inferenzmechanismus - Schlußfolgerungsmechanismus - von einer inhaltlich geprägten und deklarativ abgebildeten Wissensbasis in Form von Regel-, Objekt- oder Faktendatenbanken. Es lassen sich mehrere Ansätze unterscheiden, von denen zwei praxisrelevante Bedeutung erlangt haben. Zum einen wird das Wissen in Form von Objekthierarchien gespeichert, die hierarchische Strukturen und Abhängigkeiten von Sachverhalten oder Objekten zueinander besonders berücksichtigen (Inferenzmechanismen werden als Vererbungsmechanismen interpretiert, Hierarchien werden als Klassen, Unter- oder Oberklassen etc. dargestellt). Wichtige formale Repräsentationsformalismen sind sogenannte Frames oder objektorientierte Programmierstechniken (Näheres hierzu siehe RATH 1992, PHAM und PHAM 1988 oder HARMON und KING 1989). Zum anderen wird das Wissen in Form von Wenn-Dann-Regeln (Produktionsregeln) in Verbindung mit den logischen Junktoren  $\wedge$  und  $\vee$  dargestellt.

Und-Oder-Graph



Entscheidungstabelle

Bedingung									
A	x	x							
B			x	x					
C			x						x
D					x	x			
E								x	
Aktion									
B	x								
C		x							
D				x					
E			x						
F									x
G					x				
H						x			
I								x	

Abb. 4.5.2: Und-Oder-Graph und Entscheidungstabelle

Diese sehr verbreitete Darstellungsart leitet sich unmittelbar aus der bewährten Methode der Entscheidungstabellentechnik (siehe STRUNZ 1977) ab und resultiert in einem Und-Oder-Graph oder Entscheidungsbaum (vgl. Abb. 4.5.2), der mit Hilfe des Inferenzmechanismus durchsucht und ausgewertet werden muß. Prinzipiell lassen sich vorwärtsverkettende Verfahren (von vorhandenen Fakten neue Fakten generierend) oder rückwärtsverkettende Verfahren (von möglichen Zielen rückwärts beweisend) unterscheiden. Hierbei spielen unterschiedliche Bearbeitungs- und Regelauswahlstrategien eine wichtige Rolle (z.B. Backtracking, Breitensuche, Tiefensuche etc.). Näheres hierzu wird bei RATH (1992) oder KAINDL (1989) beschrieben.

Heutige Inferenzmechanismen im Bereich der Produktionsregelsysteme sind geprägt von der Aussagenlogik und der Prädikatenlogik, eine erweiterte Aussagenlogik, in der Aussagen mit Konstanten, Variablen und logischen Junktoren ( $\wedge$ ,  $\vee$ ,  $\neg$ ) bzw. Quantoren ( $\forall$ ,  $\exists$ ) aufgebaut werden können. Aus dem Gesetz zum modus ponens ergibt sich folgendes Beispiel:

Regel:	<i>Wenn <math>F_1</math> dann <math>F_2</math></i>	(4.5.6)
Fakt:	<i><math>F_1</math> ist wahr</i>	
Schlußfolgerung:	<i><math>F_2</math> ist wahr</i>	

In dem Beispiel gelten aufgrund der Zweiwertigkeit der klassischen Logik nur die beiden Wahrheitswerte *wahr* und *falsch*. Erweitert man diese Wahrheitswerte auf reelle Werte, ist es möglich, auch unscharfe Sachverhalte zu beschreiben. Es existieren unterschiedliche Ansätze (siehe hierzu auch KRUSE 1986): Fakten und Regeln können mit Wahrscheinlichkeiten belegt werden, die mit Hilfe des Bayes-Theorems durch den Ableitungsbaum propagiert werden. Da die a-priori-Wahrscheinlichkeiten meistens nur unzureichend bekannt sind, werden innerhalb von wissensbasierten Systemen jedoch häufiger sogenannte Certainty-Factors eingesetzt. Hierbei wird jede Aussage oder Regel mit einem heuristischen Sicherheitswert belegt, welcher durch den Ableitungsbaum auf die Schlußfolgerungen übertragen wird (Berechnungsverfahren und Beispiele siehe RATH 1992).

Neuere Anwendungen verwenden die auf ZADEH (1965) zurückgehende Fuzzy-Logik. Hierbei werden die klassischen booleschen Wahrheitswerte durch Wahrheitswertfunktionen

(Zugehörigkeitsfunktionen) ersetzt, die einer vorhandenen Größe eine Zugehörigkeit zu einer Menge zuordnen. Als Funktionen kommen Rechteck-, Dreieck-, Trapezfunktionen oder ähnliche zum Einsatz. Ausführliche Beschreibungen möglicher Funktionen liefern KAUFMANN (1975) und NEGOITA (1985). Die in der Aussagenlogik zweiwertigen Fakten werden beim Einsatz der Fuzzy-Logik zu unscharfen (fuzzy) Mengen bzw. Aussagen und der zweiwertige Produktionsregelbaum wird zu einem unscharfen System. Klassifikationsgruppen werden zu unscharfen Clustern (siehe hierzu auch die Übersicht über den Einsatz der Fuzzy-Logik innerhalb der Muster-Erkennung von PEDRYCZ 1990).

Sei  $f_{z\tilde{F}_i}$  die Zugehörigkeitsfunktion zur unscharfen Menge  $\tilde{F}_i$  über der Menge  $Q_i$ , so gilt:

$$\tilde{F}_i = \left\{ \left( q, f_{z\tilde{F}_i}(q) \right) \mid q \in Q_i \right\} \quad (4.5.7)$$

Unter Berücksichtigung dieser Definition und des von ZADEH (1975) beschriebenen Inferenzoperators kann das in Gleichung (4.5.6) beschriebene Beispiel folgendermaßen unscharf definiert werden:

Regel:  $\text{Wenn } \tilde{F}_1 \text{ dann } \tilde{F}_2$  (4.5.8)

Fakten:  $q_1 \in Q_1 = q^*, q_2 \in Q_2 = q^{**}$

Schlußfolgerung:  $\tilde{F}_3$  mit

$$Q_3 = Q_1 \times Q_2 \quad \text{und}$$

$$f_{z\tilde{F}_3} = \max \left( \min \left( f_{z\tilde{F}_1}(q^*), f_{z\tilde{F}_2}(q^{**}) \right), 1 - f_{z\tilde{F}_1}(q^*) \right) \quad (4.5.9)$$

Ein wesentliches Problem beim Einsatz der Fuzzy-Logik besteht darin, daß die Junktoren und die Schlußfolgerungsmechanismen der Aussagenlogik nicht direkt und uneingeschränkt auf unscharfe Mengen übertragen werden können. Es sind Operatoren notwendig, die die Zugehörigkeitswerte durch den unscharfen Regelbaum propagieren. Häufig wird der Junktoren  $\wedge$  (logisches Und) mit dem Minimum-Operator, der Junktoren  $\vee$  (logisches Oder) mit dem Maximum-Operator, der Junktoren  $\neg$  (Komplement) mit dem Differenz-Operator und die Schlußfolgerung mit dem Produkt-Operator oder mit dem unter Formel (4.5.9)

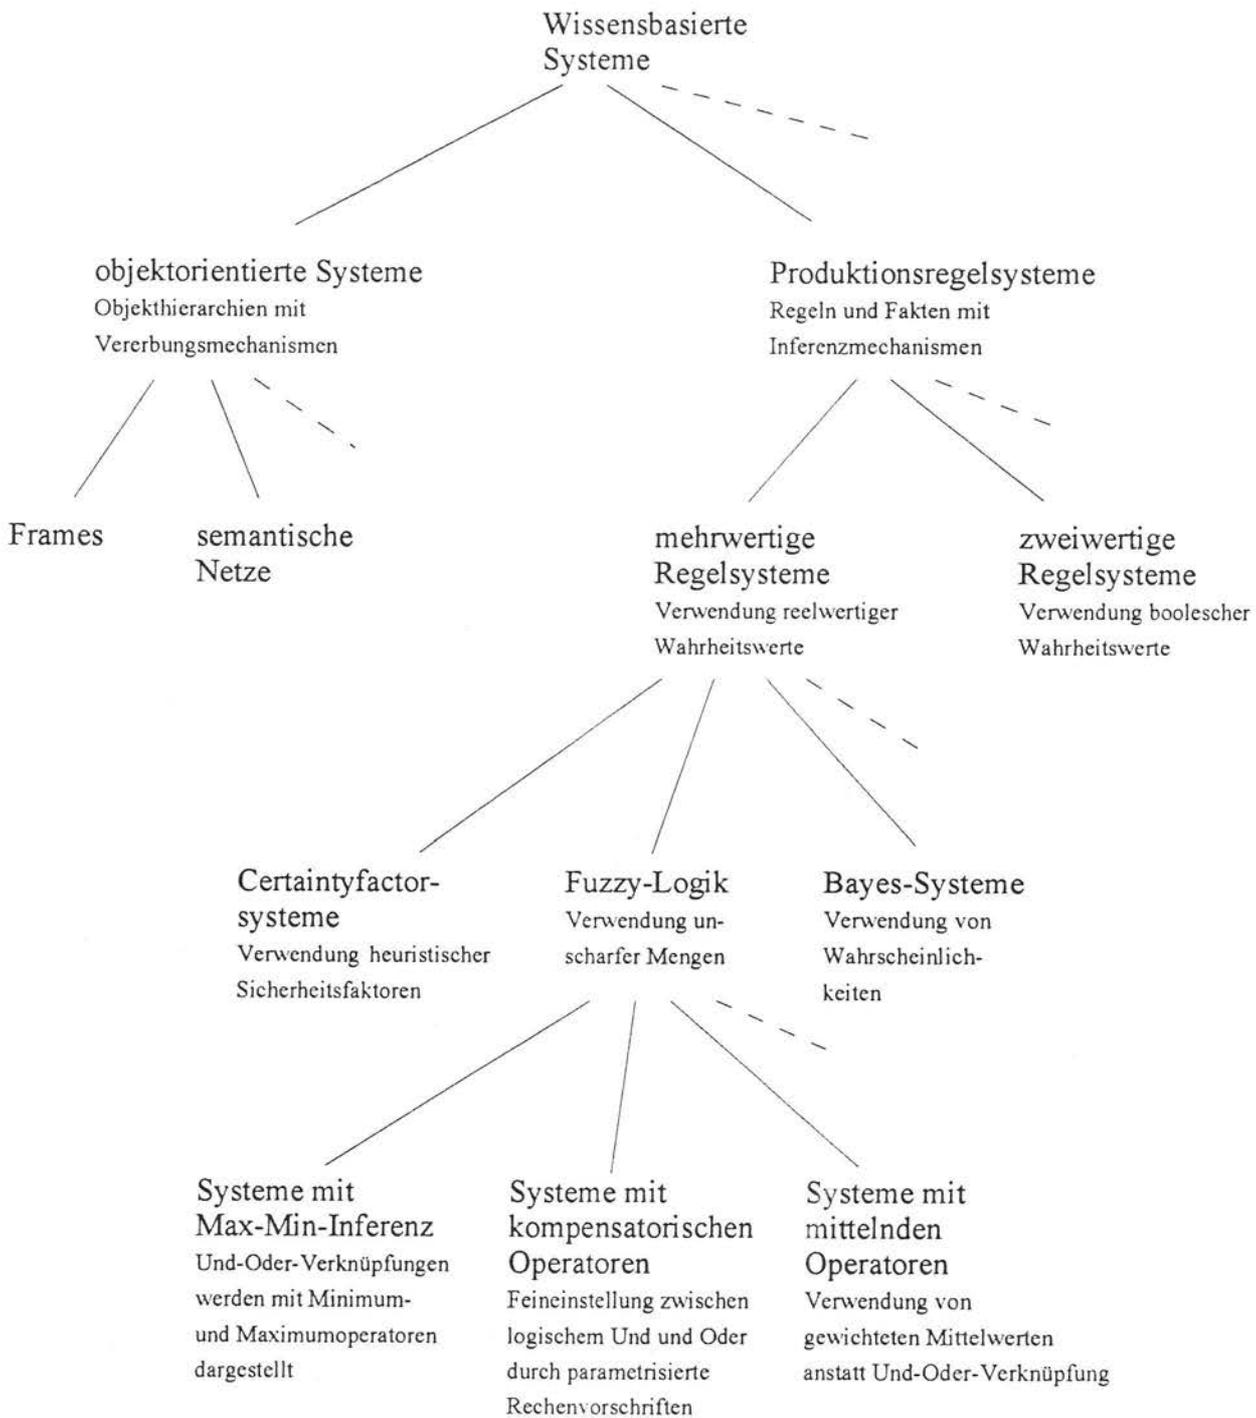


Abb. 4.5.3: Einsatz und Unterteilung wissensbasierter Systeme zur Datenauswertung

aufgeführten max-min-Operator verrechnet. Da eine scharfe Trennung zwischen  $\wedge$  und  $\vee$  mit Hilfe der Minimum- bzw. Maximum-Operatoren inhaltlich nur selten zu begründen ist (da dann bei mehreren verknüpften Prämissen nur eine Prämisse zur Gewichtung der Konklusion beiträgt), kommen zusätzlich sogenannte kompensatorische Operatoren zum Einsatz, die eine Feinjustierung zwischen logischem Und und Oder ermöglichen (siehe DRECHSEL 1996). Um eine ausgeglichene Gewichtungsscharakteristik der Regelprämissen zu erzielen, werden bei Mustererkennungsaufgaben auch Mittelwertoperatoren eingesetzt (BOTHE 1995).

Sollen am Ende des Schlußfolgerungsprozesses mehrere Zugehörigkeitsfunktionen auf einen numerischen Wert konzentriert werden, ist eine Datenverdichtung notwendig, die im allgemeinen als Defuzzifizierung bezeichnet wird. Auf eine weitere Beschreibung der Fuzzy-Logik wird an dieser Stelle bewußt verzichtet und auf die Literatur (z.B. DRECHSEL 1996) und verfügbare Tools (z.B. INFORM 1992) verwiesen.

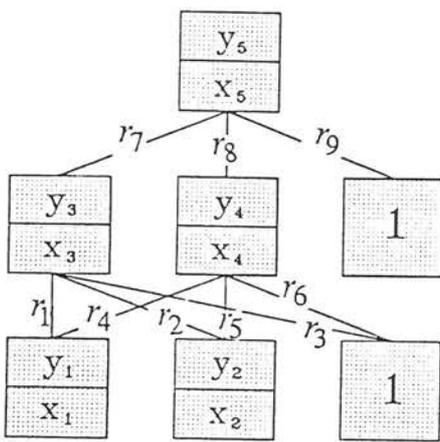
Eine zusammenfassende Darstellung der Datenauswertung mit wissensbasierten Systemen zeigt Abbildung 4.5.3.

#### 4.5.4 Neuronale Netzwerke

Unter den Begriffen Neuronales Netzwerk und Neuronales Netz werden eine Vielzahl von Datenauswerteverfahren subsummiert, die durch die Verknüpfung zahlreicher linearer und nicht linearer Funktionen einen mehrdimensionalen Datensatz auswerten bzw. verdichten. Dabei stehen weder die statistischen Kennzahlen noch die inhaltlichen Zusammenhänge der Datensätze im Vordergrund (Black-Box-Modellansatz). Neuronale Netze gegenwärtiger Prägung gehen zum großen Teil auf Arbeiten von MCCULLOCH und PITTS (1943) zurück. Besonders durch die Entwicklungen von RUMELHART et al. (1986) gehören sie heute zu den weit verbreiteten Klassifikations- und Datenauswerteverfahren (siehe auch SCHÖNEBURG et al. 1990), die auch besonders im Bereich der Bildverarbeitung eingesetzt werden können (siehe hierzu KULKARNI 1994).

Neuronale Netze bestehen aus Verarbeitungseinheiten, welche mit einer Inputfunktion numerische Eingangswerte zusammenfassen, mit einer Transferfunktion auswerten und mit

einer Outputfunktion ausgeben. Eine Verarbeitungseinheit wird auch als Netzelement oder Neuron bezeichnet. Eine übliche Inputfunktion ist die Summation der gewichteten Eingänge (Gewichtung der Verbindung multipliziert mit Wert der Verbindung). Typische Outputfunktionen sind die Identitätsfunktion oder Schwellenwertfunktionen, die den Output je nach Ausgabe der Transferfunktion auf binäre Werte setzen. Die gebräuchlichsten Input-, Transfer- und Outputfunktionen finden sich bei SCHÖNEBURG et al. (1990). Im weiteren wird als Inputfunktion von der Summenfunktion und bei der Outputfunktion von der Identitätsfunktion ausgegangen (vgl. auch Abb. 4.5.4).



$$y_i = f_t(x_i)$$

$$x_3 = r_1 y_1 + r_2 y_2 + r_3$$

$$x_4 = r_4 y_1 + r_5 y_2 + r_6$$

$$x_5 = r_7 y_3 + r_8 y_4 + r_9$$

Abb. 4.5.4: Informationsweitergabe in einem 3-schichtigen neuronalen Netz

Durch den Zusammenschluß mehrerer Netzelemente mit gewichteten Verbindungen ist es möglich, Information durch das Netz zu propagieren und auszuwerten. Mehrere Netzelemente können zu Schichten zusammengefaßt werden, die wiederum mit anderen Schichten ein Gesamtnetz ergeben. Verbindungen können rückgekoppelt oder von Schicht zu Schicht (feed forward) orientiert sein.

Abbildung 4.5.5 zeigt ein Beispiel eines drei-schichtigen Netzes. Die Informationsverarbeitung erfolgt, indem Netzelemente (in der Regel die Eingabeschicht) mit dem Merkmalvektor belegt werden. Anschließend werden die Daten entsprechend der Netztopologie und den Propagierungs- und Verknüpfungsfunktionen durch das Netz transferiert und an die Ausgabestellen bestimmter Netzelemente (Ausgabeschicht) als Modellergebnis weitergeleitet. In

dem dargestellten Beispiel würde ein 10-dimensionaler Merkmalvektor auf einen 13-dimensionalen Klassifikationsvektor (z.B. Gruppenzugehörigkeit zu 13 verschiedenen Gruppen) abgebildet. Damit diese Abbildung optimal (d.h. mit maximaler Trennschärfe) durchgeführt wird, muß bei der Modellbildung erstens die Auswahl des Netztypus, der Netzelemente, der Schichten, der Netzelementfunktionen, der Verbindungen etc. und zweitens die Bestimmung der Verbindungsgewichte (Gewichtsmatrix) zwischen den einzelnen Netzelementen erfolgen. Die ersten Faktoren sind vergleichbar mit der Modellauswahl innerhalb der klassischen Datenanalyse und werden vom Modellentwickler aufgrund von Vorversuchen oder Erfahrungen ausgeführt. Im allgemeinen ist es schwierig, die optimale Netzdimensionalität festzulegen (siehe hierzu auch FU 1990).

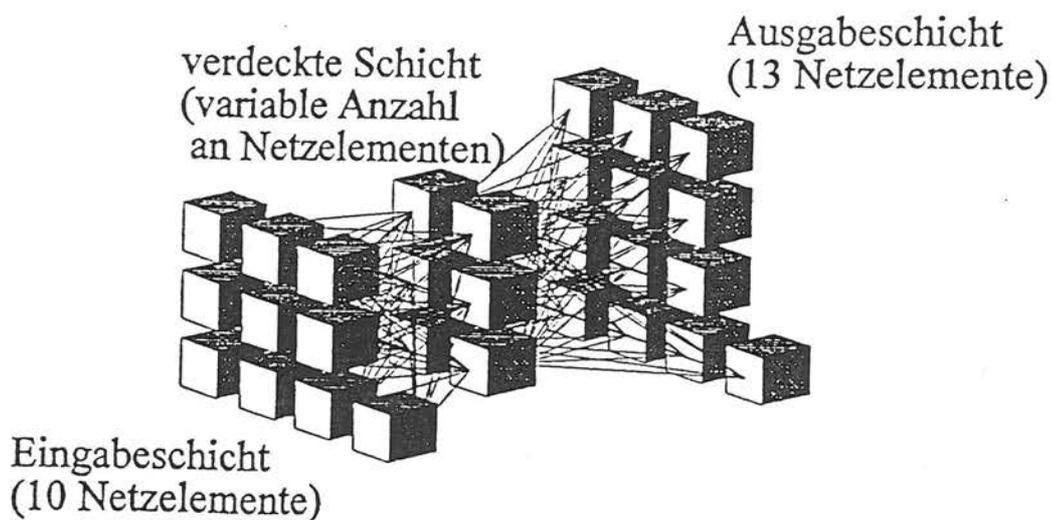


Abb. 4.5.5: Schemazeichnung eines drei-schichtigen, nicht rückgekoppelten Netzwerkes

Die Bestimmung der optimalen Netzgewichtsmatrix kann entweder durch überwachtes Lernen oder durch unüberwachtes Lernen erfolgen (siehe KRATZER 1993 oder SCHÖNEBURG et al. 1990). Im ersten Fall werden die Datensätze des Lerndatensatzes einschließlich der bekannten Gruppenzugehörigkeiten (abhängige Variable) zur Matrixbestimmung benutzt. Im zweiten Fall versucht das Netz eigenständig, sich anhand des Lerndatensatzes zu organisieren (entspricht also eher der Clusteranalyse). Wichtigstes Lernverfahren (überwachtes Verfahren) ist das sogenannte Backpropagation-Lernen (siehe RUMELHART et al. 1986): Nach

Anlegen eines Lernvektors werden die Ausgabewerte des Netzes feed forward berechnet und mit den Soll-Ausgaben verglichen. Der entstehende Fehler führt zur Adaption der Gewichtsmatrix nach folgender Rekursion:

$$\Delta r_{ij} = \lambda \delta_j s_i \quad \text{mit} \quad (4.5.10)$$

$$\delta_j = \begin{cases} f'_t(x_j) (s^*_j - s_j) & \text{falls Element } j \text{ ein Ausgabeelement ist} \\ f'_t(x_j) \sum_k \delta_k r_{jk} & \text{sonst} \end{cases}$$

$\lambda$ : Lernrate

$\delta_j$ : Fehler von Netzelement  $j$

$s_i$ : Ausgabewert (Ergebnis der Outputfunktion) von Netzelement  $i$  ( $*$  = Sollwert)

$f'_t$ : erste Ableitung der Transferfunktion

$x_j$ : Eingangswert (Ergebnis der Inputfunktion) von Netzelement  $j$

$r_{ij}$ : Verbindungsgewicht zwischen Netzelement  $i$  und nachfolgendem Element  $j$

Das Verfahren wird mit zufälliger Intialisierung der Gewichte gestartet und endet nach wiederholtem Anlegen der verschiedenen Lernvektoren. Die so im Hillclimbing bestimmte Gewichtsmatrix kann in Verbindung mit dem entsprechenden Netz zur Auswertung neuer Merkmalvektoren eingesetzt werden. Eine wichtige Variationen des Backpropagation-Verfahrens ist der Einsatz eines Momentumterms, der die Veränderung der Verbindungsgewichte von der Veränderung im letzten Lernschritt abhängig macht (zu  $\Delta r$  wird  $x\Delta r_{(\text{letzter Lernschritt})}$  mit  $x$ =Momentum addiert (siehe ZELL et al. 1994)).

Weitere Lernverfahren, Berechnungen und Beispiele zum überwachten und unüberwachten Lernen zeigen RITTER et al. (1991). Beispiele aus dem Bereich der Pflanzenklassifikation mit verschiedenen Netzarchitekturen und Lernverfahren finden sich bei RATH (1995a). Auf eine tiefere Beschreibung neuronaler Netzwerke wird an dieser Stelle bewußt verzichtet. Es wird auf die zahlreich vorhandene Literatur zu diesem Thema, auch speziell im

Bereich der Bildverarbeitung ( z.B. KULKARNI 1994), verwiesen. Ein mögliche Einteilung neuronaler Netze zur Datenauswertung zeigt Abbildung 4.5.6.

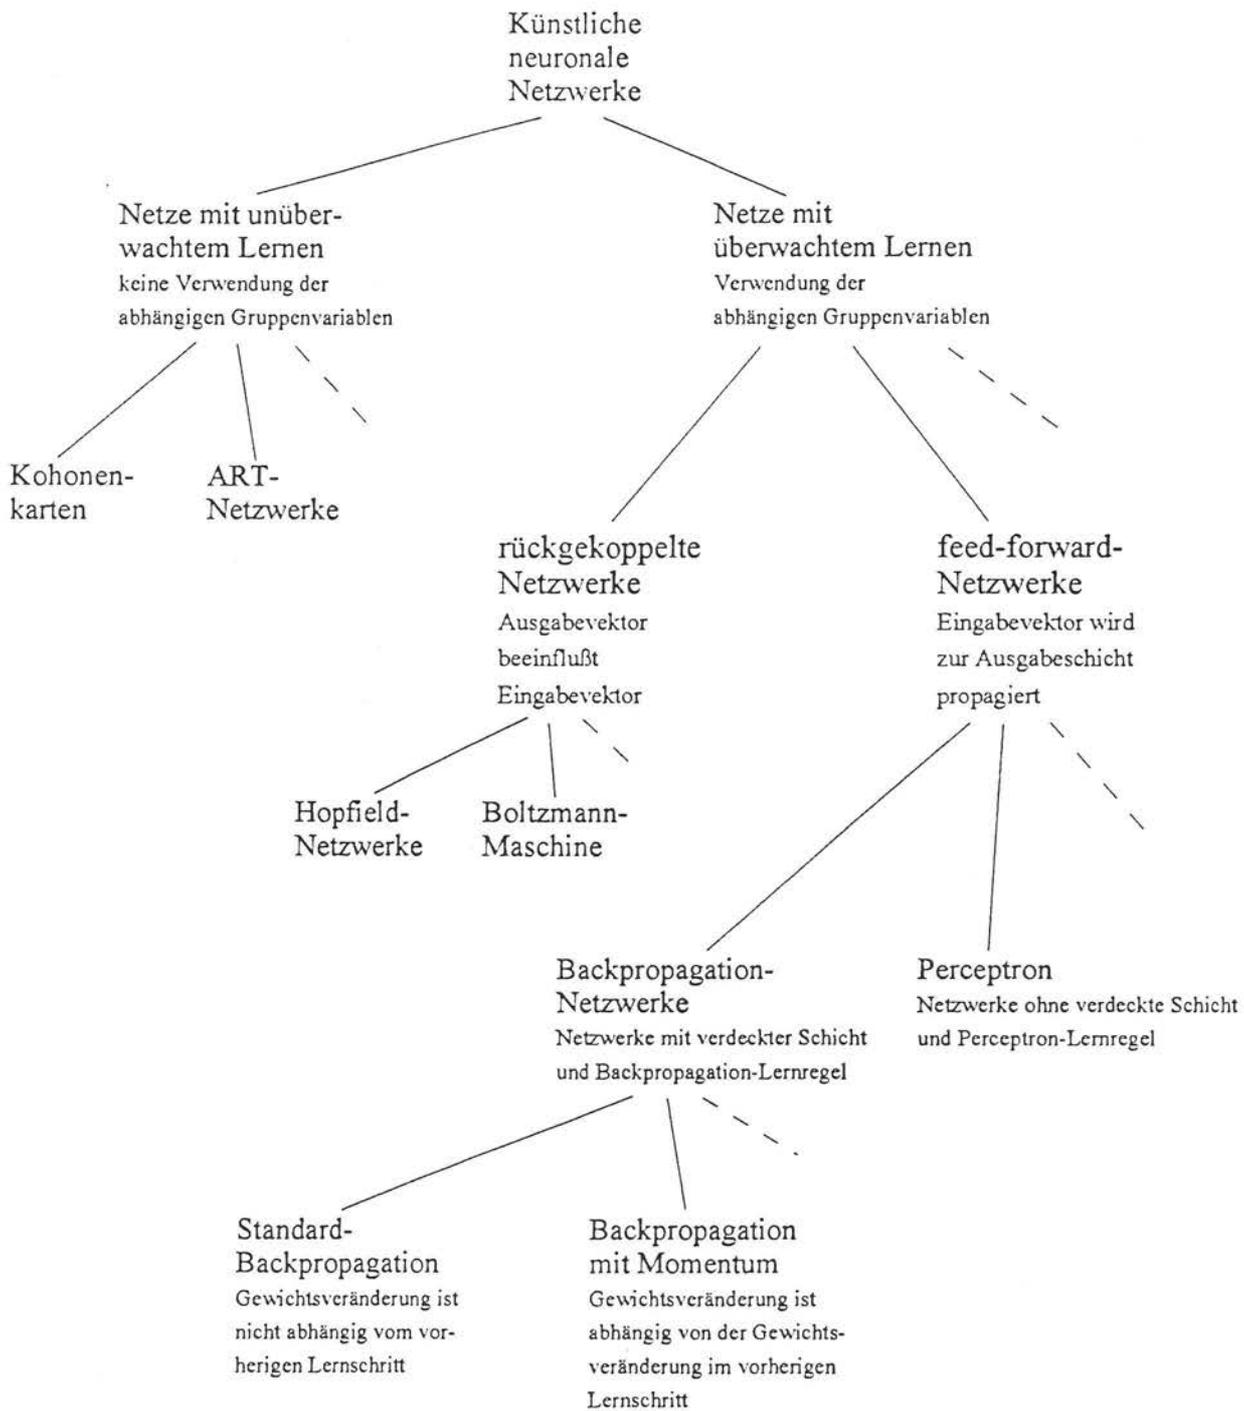


Abb. 4.5.6: Einsatz und Unterteilung neuronaler Netze zur Datenauswertung

## 5. Material und Methoden

### 5.1 Verwendetes Pflanzenmaterial und Bildaufnahmen

Grundlagen der Untersuchungen waren eingescannte Laubblätter einheimischer Laubgehölze. Die Auswahl der Arten erfolgte nach folgenden Gesichtspunkten:

1. Auswahl wichtiger und häufig vorkommender Baumarten
2. Auswahl von Arten, die eventuell mit den Arten unter 1 verwechselt werden können
3. Auswahl von weiteren Arten der gleichen Gattung

Die Blätter wurden alle in Hannover oder der näheren Umgebung gesammelt, mit den beschriebenen Bestimmungsschlüsseln bestimmt oder direkt von bereits bestimmten Pflanzen aus dem Berggarten Hannover entnommen. Bei der Auswahl der Blätter wurde darauf geachtet, daß sowohl große als auch kleine Blätter in unterschiedlichen Entwicklungsstadien und von unterschiedlichen Individuen entnommen wurden. Bei selteneren Arten (z.B. *Pterocarya fraxinifolia*) mußte jedoch z.T. auf die Bedingung, daß jedes Blatt von einem anderen Baum stammt, verzichtet werden, da nur wenige oder auch nur einzelne Pflanzen zur Verfügung standen.

Die Laubblätter wurden mit einem Din A4-Schwarz-Weiß-Flachbettscanner mit weißem Hintergrund mit einer Auflösung von 150 dpi und 256 Graustufen in zufälligen Auflagerichtungen eingescannt. Von einigen Blättern jeder Art wurde eine zweite Aufnahme mit veränderter Auflageausrichtung gemacht (Drehung um 90° bis 180 ° gegenüber der ersten Aufnahme). Bei einigen Arten konnten nicht alle Blätter verwendet werden, da sie aufgrund ihrer Gesamtgröße oder aufgrund ihrer Stiellänge nicht vollständig auf den Scanner paßten. Ferner wurde die Art *Nothofagus antarctica*, die ursprünglich zur Bestimmung mit eingesetzt werden sollte, nicht weiter verwendet, da sie im Vergleich zu den anderen eingesetzten Arten zu kleine Blättchen besaß. Insgesamt wurden 51 Arten in die Untersuchungen aufgenommen, die sich wie folgt auf die einzelnen Gattungen aufteilen (in Klammern die Anzahl der Arten):

*Acer* (6), *Aesculus* (1), *Alnus* (2), *Betula* (3), *Carpinus* (1), *Carya* (1), *Castanea* (1), *Cercidiphyllum* (1), *Cersis* (1), *Corylus* (2), *Crataegus* (1), *Fagus* (1), *Fraxinus* (1), *Gleditsia* (1),

*Ginkgo* (1), *Juglans* (2), *Laburnum* (1), *Liriodendron* (1), *Magnolia* (1), *Platanus* (1), *Populus* (3), *Prunus* (1), *Pterocarya* (1), *Pyrus* (1), *Quercus* (5), *Robinia* (1), *Salix* (2), *Sophora* (1), *Sorbus* (3), *Tilia* (2), *Ulmus* (1).

Von jeder Art wurden 15 Aufnahmen erstellt. Für die Bildung der Auswertemodelle wurden jeweils 10 Aufnahmen von 9 verschiedenen Blättern nach den Kriterien Bildschärfe und Vollständigkeit des Blattes und der Blattaufnahme ausgewählt. Die zwei Aufnahmen von einem Blatt resultierten jeweils aus unterschiedlichen Auflageausrichtungen. Eine vollständige Auflistung der Arten mit beispielhaften Binärbildern der eingescannten Blätter findet sich im Anhang. Abbildung 5.1.1 zeigt exemplarisch das für die Untersuchungen verwendete und als Bitmap-Grafik (Tif-Format) abgespeicherte Bild einer Stieleiche (*Quercus robur*).

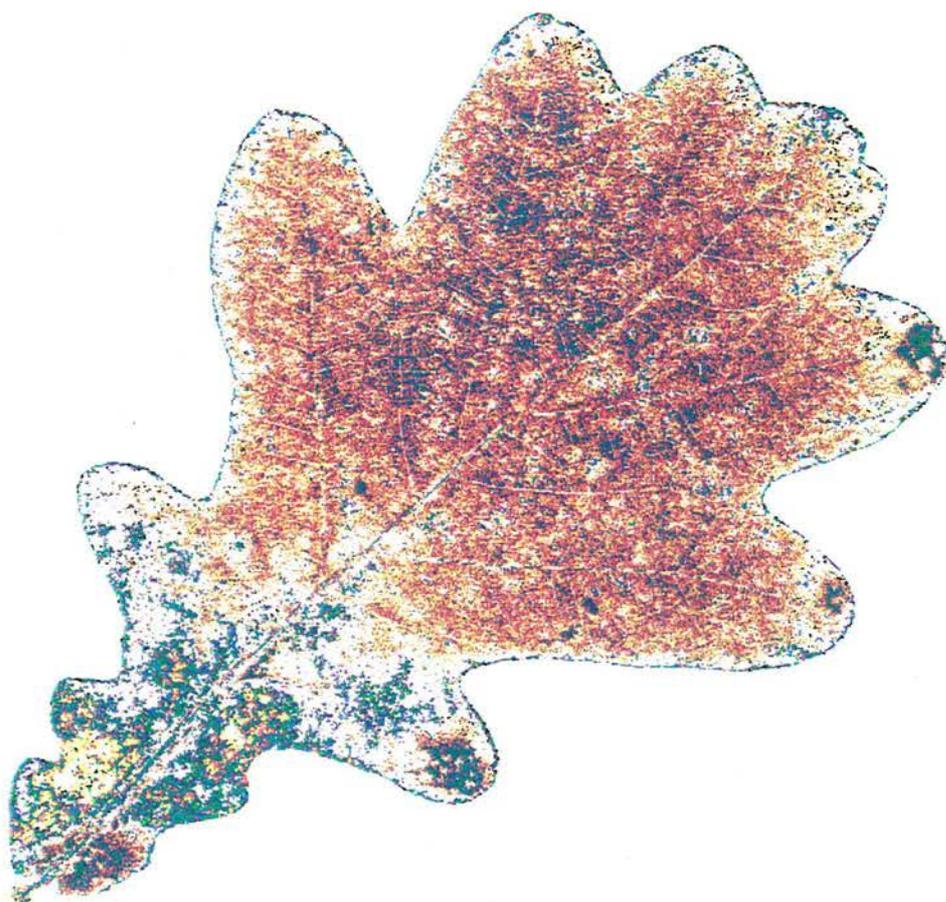


Abb. 5.1.1: Eingescanntes Bild einer Stieleiche (*Quercus robur*) - Erklärungen im Text

Zur besseren Visualisierung sind die Grauwerte in Falschfarbendarstellung abgebildet. Sie wurden vorher manuell optimal aufbereitet und auf 16 Grauwerte verdichtet. Das Bild verdeutlicht die maximal erzielbare Objektauflösung innerhalb der Blattspreite.

## 5.2 Blattmerkmale und deren Parametrisierung

Aus Kap. 3 wird deutlich, daß ein wesentlicher Schritt zur computerbildanalytischen Pflanzenbestimmung in der Auswahl und Parametrisierung einzelner Pflanzen- bzw. Blattmerkmale besteht. Ziel muß es sein, die wichtigen numerische Parameter, die direkt oder in Verbindung mit anderen Parametern zur Klassentrennung beitragen, zu extrahieren, während andere Merkmale, die evtl. nur Scheinkorrelationen erzeugen, nicht genutzt werden sollten. Da die Pflanzentaxonomie im wesentlichen auf botanisch morphologischen Kriterien aufbaut, orientiert sich die Merkmalextraktion und -parametrisierung innerhalb dieser Arbeit streng an den in den Bestimmungsschlüsseln vorgeschlagenen Merkmalen.

Zur Bestimmung von Laubgehölzen anhand ihrer Laubblätter werden bestimmte Blattorgane oder Blattunterteilungen eingesetzt (siehe Abb. 3.2). Die computergestützte Pflanzenbestimmung setzt daher eine bildanalytische Separierung der einzelnen Blattabschnitte voraus. Für die weiteren Analysen wurden von den in Abb. 3.2 beschriebenen Blattunterteilungen folgende Unterteilungen computerbildanalytisch extrahiert und weiter ausgewertet: **Blattspreite**, **Blattstiel**, **Spreitenbasis**, **Spreitenspitze**, **Blättchen** und **Blattlappen** (hinzu kommt noch die Stellung der Blätter am Zweig, was eigentlich den Zweig als Bestimmungsorgan voraussetzt).

Die Algorithmen zur automatischen Erkennung und Extraktion dieser Blattbereiche werden in Kap. 5.3 näher beschrieben. Auf die Verwendung der Merkmalbereiche Blatthälften, Blattoberseite und Blattunterseite wurde aus folgenden Gründen verzichtet: Die Blatthälftendifferenzierung trägt nur bei sehr wenigen Arten zur Klassifikation bei und führt bei vielen Blättern aufgrund von Wachstumsunterschieden zu Fehlinterpretationen. Ferner kann der unterschiedliche Aufbau von Blatthälften auch mit Formparametern für die gesamte Blattspreite erfolgen. Die Unterteilung in Blattober- und -unterseite betrifft in der Regel

farbspezifische oder spezielle Merkmale (z.B. Behaarung), die mit der gewählten Grauwert-technologie nicht zu erfassen sind.

Nach Extraktion der einzelnen Blattbereiche mußten die in den Bestimmungsschlüsseln verwendeten Merkmale parametrisiert werden. Botanische Merkmale mit numerischem Charakter (Anzahl, Länge, Breite, Fläche), konnten direkt aus der Anzahl der Punktmengen, der Pixelanzahl oder aus der Bildauflösung und den Radien des kleinsten umschließenden, an der Blattachse orientierten Rechteckes (vgl. Formel 4.3.23) ermittelt werden.

Formeigenschaften der Blattspreite, der Spreitenbasis und der Spreitenspitze wurden mit mehreren numerischen Werten repräsentiert. Im folgenden werden die verwendeten Kennzahlen und die jeweilige Begründung für deren Verwendung dargestellt. Auf das wichtige Formmerkmal des Verhältnisses der Objektlänge zur Objektbreite wird nicht weiter eingegangen, da es innerhalb der Bestimmungsschlüssel direkt numerisch eingesetzt wird.

Eine wichtige Kennzahl zur Beschreibung einer geometrischen Form ist das Verhältnis der Fläche der konvexen Hülle zur Objektfläche, welche als **Konvexität** bezeichnet wird (vgl. Formel 4.4.7). Beträgt die Konvexität 1, hat das Objekt keine Einbuchtungen oder Einschnitte und stellt eine geometrische Grundform (Gerade, Kreis, Rechteck, Vieleck etc.) dar. Mit Hilfe der Konvexität lassen sich gelappte, gebuchtete oder eingeschnittene Blattformen von einfachen Blattformen (linealisch, eiförmig etc.) unterscheiden. Ebenso kann zwischen Spezialformen (gefingert, keilförmig etc.) und einfachen Formen differenziert werden. Eine Unterscheidung zwischen tief und eng eingeschnittenen und weit gebuchteten oder z.B. regelmäßig gezackten Formen ist mit der Konvexität nicht möglich, da sie nicht die Umrißlänge berücksichtigt. Aus diesem Grund wird als weiterer Formparameter die **Kompaktheit** eingesetzt. Sie berücksichtigt das Verhältnis zwischen Umfang und Fläche einer Kontur. Bei konvexen Objekten kann mit Hilfe der Kompaktheit auch gut zwischen langgezogenen (z.B. linealisch) und kompakten (z.B. eiförmig, rund) Formen unterschieden werden. Da die Blattformen jedoch in der Regel mehr oder weniger unkonvex, d.h. eingeschnitten, gezähnt oder gebuchtet sind, läßt sich eine sichere Unterscheidung zwischen langgezogenen, rundlichen oder mehr eckigen Blattformen allein mit der Kompaktheit nicht erzielen. Es wurden daher drei weitere Formparameter verwendet, die auf dem Vergleich zwischen der aus einer geometrischen Grundform entwickelten Fläche und der Objektfläche

basieren. Als geometrische Grundformen wurden Kreis, Ellipse und Rechteck gewählt. Um eine maximale Aussagekraft der Parameter zu erzielen, basierte die Bildung der geometrischen Vergleichsobjekte jeweils auf unterschiedlichen Verfahren. Um weitestgehende Größenunabhängigkeit zu erzielen, wurde in allen Fällen das Ergebnis mit Hilfe der Objektfläche normiert. Zur Bestimmung der **Rundheit** wurde der umschließende Kreis als Vergleichsobjekt verwendet. Die Kreisfläche wurde demnach auf die maximale Objektausdehnung bezogen. Bei der Bestimmung der **Elliptizität** wurde eine spezielle Vergleichsfläche, bestehend aus einer auf die Objektfläche normierten Ellipse und der Objektfläche verwendet. Die Ausrichtung der Ellipse erfolgte anhand der Schwerpunktklinien des zu untersuchenden Objektes. Eine noch weitergehende Einschränkung der Ausrichtung des Vergleichsobjektes erfolgte bei der Verwendung des umschließenden Rechteckes. Hier wurde das Objekt anhand der Spreitenachse (Verbindungsline zwischen Stielansatz und äußerste Blattspitze) ausgerichtet. Der resultierende Parameter wird im folgenden als **Eckigkeit** bezeichnet. Neben der Erfassung von abgestumpften oder eckigen Formen, die besonders bei der Differenzierung der Spreitenbasis und der Spreitenspitze von Bedeutung sind, kann mit diesem Parameter auch die Ausrichtung der Objektform in Längs- oder Querrichtung parametrisiert werden (Berechnungen siehe Kap. 5.3).

Aufgrund der großen Bedeutung der Blattspreitenform zur Pflanzenbestimmung wurden alle beschriebenen 5 Formparameter auf die Blattspreite angewendet. Bei der Analyse des Blattgrundes und der Blattspitze wurde auf die Rundheit und die Elliptizität verzichtet, da das Analyseobjekt aus einer künstlich mit einer geraden Trennlinie erzeugten Form bestand. Ebenso wurde auf die Kompaktheit verzichtet, da die allgemeinen Kompaktheitseigenschaften bereits innerhalb der Blattspreite erfaßt wurde. Da die Unterteilung der Blattspreite in Spreitenbasis und Spreitenspitze auf einer fest definierten Unterteilung der Blattachse beruht, können mit den bisherigen aufgeführten Parametern nur unzureichende Aussagen über den Verlauf der Blattspitze im Verhältnis zum Gesamtblatt gemacht werden (das Verhältnis der Länge zu Breite der Spreitenspitze sagt nur wenig über die „Langezogenheit“ oder die „Stacheligkeit“ der Spitze aus). Aus diesem Grund wurde zur Formbeschreibung der Spreitenspitze das Verhältnis der Spreitenspitzenfläche zur Gesamtspreitenfläche in die Parametrisierung mit aufgenommen. Auf den Einsatz der vorgestellten Formparameter zur Parametrisierung der Blättchen und der Blattlappen wurde verzichtet, da sie in den Bestim-

mungsschlüsseln nur von untergeordneter Rolle sind und da sie zum Teil mit den Formparametrisierungen der gesamten Blattspreite abgedeckt wurden.

Neben den beschriebenen Merkmalen ist die Blattrandfeinstruktur für die Pflanzenunterscheidung von großer Bedeutung. Eine Parametrisierung mit Formkennzahlen - wie oben beschrieben - war nicht möglich, da die Blattrandfeinstrukturen immer von den Grobstrukturen des Blattrandes (Einbuchtungen, Einschnitte) überlagert werden. Stattdessen wurde die Blattrandfeinstruktur mit Hilfe dreier, aus dem Kettencode der Blattkontur gewonnenen Parameter dargestellt. Zwei der drei Parameter beschreiben die Häufigkeit von großen Richtungswechseln innerhalb des Codes. Sie stellen quasi die Stärke der Zähnung oder Kerbung des Blattrandes dar. Der dritte Parameter resultiert aus der Regelmäßigkeit der Richtungswechsel und kann als Parametrisierung der Gleichmäßigkeit oder Schwankung der Zähnung interpretiert werden (z.B. einfach oder doppelt gezähnt). Zur Bestimmung der Parameter wurde jeweils nur der Blattrandabschnitt ausgewählt, der die deutlichste Zähnung besaß. Eine genaue Beschreibung der Auswahl- und Berechnungsverfahren mit Blattbeispielen findet sich in Kap. 5.3.7.

Innerhalb der in Kap. 3 vorgestellten Bestimmungsschlüssel ist die Stellung der Blätter am Zweig von zentraler Bedeutung zur richtigen Abarbeitung der Entscheidungsbäume. Eine Modellierung der Pflanzenerkennung, die auf direkter Umsetzung dieser Bestimmungsschlüssel aufbaut, kann demnach nicht auf die Verwendung dieses Merkmals verzichten (ansonsten sind die Bestimmungsschlüssel nicht mehr einsetzbar). Wie schon zu Beginn dieses Abschnittes angedeutet, gehört die Blattstellung zwar zu den Blatteigenschaften, kann aber letztlich nur in Verbindung mit der Analyse eines Zweiges durchgeführt werden. Da die eingesetzte Aufnahmetechnik schon Probleme bereitete, wenn große oder größere Blätter eingescannt wurden, war eine Erfassung eines Zweiges oder Zweigabschnittes mit dem verwendeten Din-A4-Scanner unmöglich. Aus diesem Grund wurde die Blattstellung beim Einscannen eines Blattes als numerische Zusatzinformation (1 = gegenständig, 0 = wechselständig) extern in den Rechner eingegeben. Das Merkmal wurde allerdings nur beim Einsatz wissensbasierter Modelle zur Pflanzenidentifikation verwendet. Eine automatische Erkennung dieses Merkmals könnte bei anderer Scanner-Technik ohne weiteres mit den beschriebenen Filtertechniken durchgeführt werden, da ein Zweig mit Blättern genauso com-

puterbildanalytisch bearbeitet werden kann wie ein zusammengesetztes Laubblatt mit einzelnen Blättchen.

Innerhalb der Bestimmungsschlüssel von FITSCHEN (1994) und GODET (1987) wird häufig auf den Verlauf der Blattaderung zurückgegriffen. Es wird allgemein zwischen Netznervigkeit und Parallelnervigkeit sowie zwischen einigen Spezialverläufen (z.B. gabelig) unterschieden. Wachstumsverzweigungen lassen sich prinzipiell mit Verfahren aus der fraktalen Geometrie beschreiben oder modellieren. CARL et al. (1993) stellen den Einsatz eines solchen Verfahrens zur Analyse von Wurzelsystemen vor. Dieses Verfahren kann modifiziert auf die Blattadernanalyse angewandt werden: Nach Herausfilterung der Blattadern (als Punktmenge) wird das Ergebnisbild mit Hilfe eines vorgegebenen Rasters in Einzelbilder unterteilt. Anschließend wird untersucht, welche Einzelbilder keine Punkte (d.h. keine Blattadernteile) enthalten. Wiederholt man dieses Verfahren mit immer feinerer Rasterung, d.h. mit immer zahlreicher und kleiner werdenden Einzelbildern, und trägt die Anzahl der jeweils gesamten Rasterbilder gegenüber der Anzahl der leeren Einzelbilder in logarithmischem Maßstab auf, ergibt die Steigung der Ausgleichsgeraden die sogenannte Box-Counting-Dimension, eine Maßzahl für die Fraktalität des Untersuchungsobjektes. Abbildung 5.2.1 stellt das Ergebnis der Durchführung des Verfahrens an verschiedenen Blättern einer Linde (*Tilia cordata*) dar. Bei anderen untersuchten Arten ergeben sich deutlich größere Streuungen der Werte.

Der Einsatz des Verfahrens setzt eine exakte und vor allen Dingen für alle Blätter gleiche Extraktion der Blattaderung aus den Grauwertbildern voraus. Abbildung 5.2.2 stellt die notwendigen Bildverarbeitungsschritte und das damit erzeugbare Ergebnisbild (Punktmengenbild) einer speziell auf die Aderextraktion ausgerichteten Computerbildverarbeitung an einem Blatt von *Quercus robur* (vgl. Abbildung 5.1.1) dar. In Vorversuchen konnten von einigen Blättern ähnlich gute Binärbilder erzeugt werden, bei dem überwiegenden Teil der Blätter waren die Extraktionen jedoch unbefriedigend, da

- die Blattadern nicht deutlich genug sichtbar waren,
- die notwendigen Extraktionsalgorithmen nicht verallgemeinerbar waren,
- Laubfärbungen und Blattaufhellungen die Grauwertdifferenzen der Blätter verursachten.

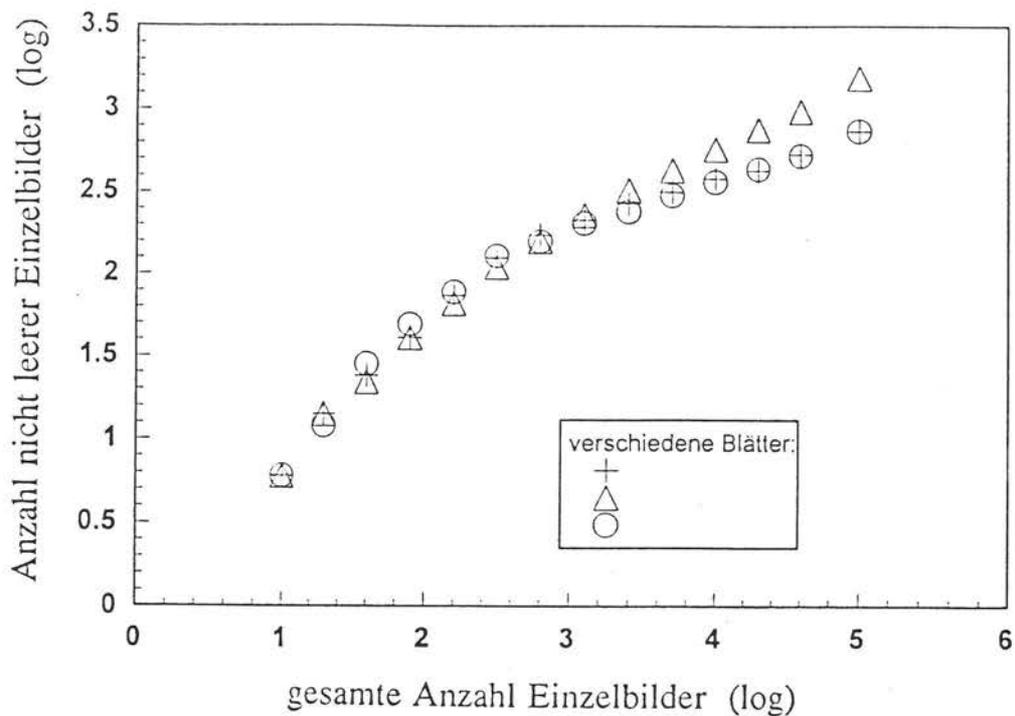
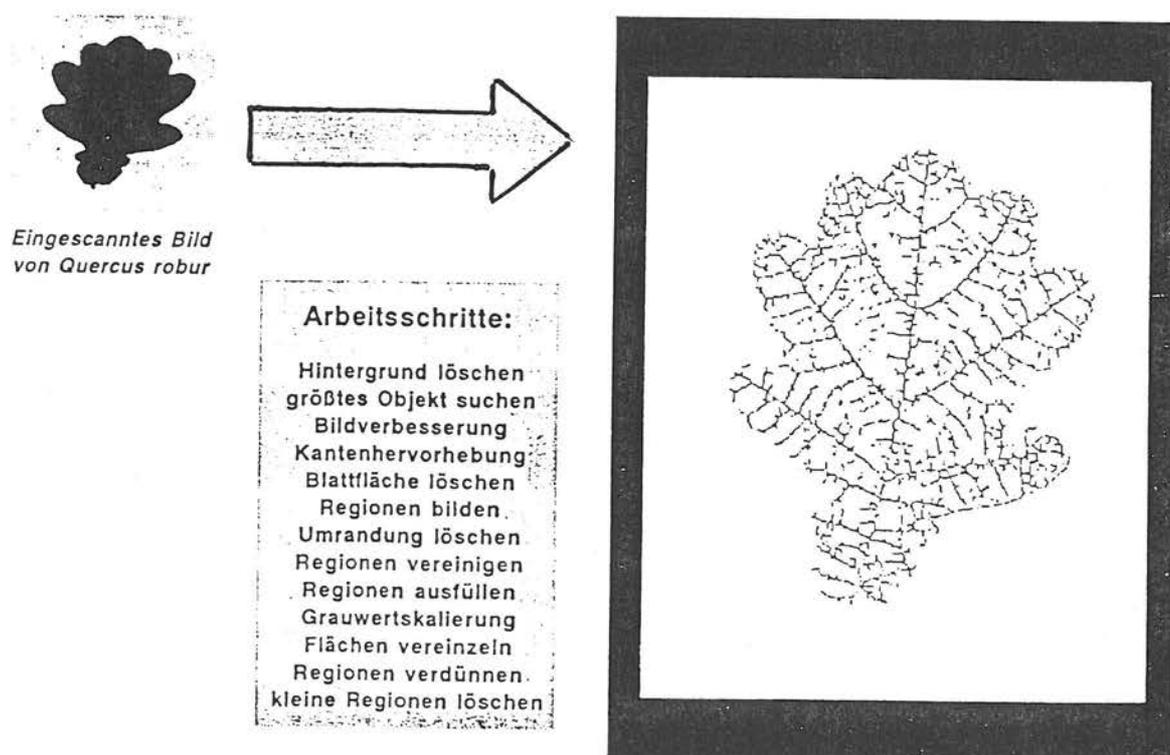


Abb. 5.2.1: Box-Anzahl verschiedener Linden-Blätter (*Tilia cordata*)



### 5.2.2 Bildverarbeitungsschritte zur Separierung der Blattnervatur

Als Beispiel für die schwierige Grauwertanalyse zur Aderextraktion sei auf das mit sehr blattspezifischen Operationen erzeugte Falschfarbenbild in Abb. 5.1.1 hingewiesen. Die Versuche, mit Hilfe von Polygonenzügen oder der Hough-Transformation die Aderung zu modellieren bzw. zu extrahieren, erbrachten keine wesentliche Verbesserung der Ergebnisse. Aufgrund der dargestellten Unzulänglichkeiten bei der Aderextraktion mußte für die weiteren Untersuchungen auf das Blattmerkmal Aderung verzichtet werden.

Auf die Nutzung der in Abbildung 3.2 unter „sonstige spezielle Merkmale“ aufgeführten Unterscheidungsmerkmale wurde ebenso verzichtet, da sie entweder nur bei wenigen Arten von Bedeutung sind oder aber aus dem vorhandenen Bildmaterial mit der eingesetzten Aufnahmetechnik nicht extrahierbar waren.

Tabelle 5.2.1 stellt die verwendeten Merkmale, ihre Parametrisierung, Bezeichnung und Verwendung in den Auswertemodellen übersichtlich dar.

Tab. 5.2.1: Parametrisierung und Verwendung von Blattmerkmalen

Organ, Teil	botanisches Merkmal	Parametrisierung mit	Vari- able	Verweis	Verwendung *		
					wS	nsf	kA
Zweig	Blattstellung	manuelle Eingabe	$\varphi_1$	Kap. 5.2	ja	nein	(ja)
Blatt- spreite	Aufbau (einf., zus.ges.)	morphol. Filterung	$\varphi_2$	Kap. 5.3.2	ja	ja	ja
	Anzahl Blättchen	morphol. Filterung	$\varphi_3$	Kap. 5.3.5			
	Anzahl Blattlappen	morphol. Filterung	$\varphi_4$	Kap. 5.3.6			
	Blattfläche	Pixelfläche	$\varphi_5$	Kap. 5.3.4			
	Länge zu Breite	Rechteckradien	$\varphi_6$				
	Form	Konvexität	$\varphi_7$				
		Kompaktheit	$\varphi_8$				
		Rundheit	$\varphi_9$				
		Elliptizität	$\varphi_{10}$				
	Blattrand- feinstruktur	Kettencodeanalyse	$\varphi_{12}$	Kap. 5.3.7			
		Kettencodeanalyse	$\varphi_{13}$				
Kettencodeanalyse		$\varphi_{14}$					
Blattstiel	Länge	Rechteckradien	$\varphi_{15}$	Kap. 5.3.2			
Spreiten- spitze	Länge zu Breite	Rechteckradien	$\varphi_{16}$	Kap. 5.3.3			
	Form	Konvexität	$\varphi_{17}$				
		Eckigkeit	$\varphi_{18}$				
		Spitzenfl./ Blattfl.	$\varphi_{19}$				
Spreiten- basis	Länge zu Breite	Rechteckradien	$\varphi_{20}$	Kap. 5.3.3			
	Form	Konvexität	$\varphi_{21}$				
		Eckigkeit	$\varphi_{22}$				
Blattadern	Verzweigungsform	fraktale Geometrie	--	Kap. 5.2	nein	nein	nein

\* wS = wissensbasierte Systeme, nsf = künstliche neuronale Netzwerke, statistische Verfahren, Fuzzy-Logik  
kA = kombinierte Ansätze, (ja) = nur im wissensbasierten Teil

## 5.3 Entwickelte Bildbearbeitungsalgorithmen

### 5.3.1 Bildaufbereitung

Die eingescannten Bilder wurden mit Grauwertfiltern aufgearbeitet und in Binärbilder überführt. Zur Extraktion der Blattnervatur wurden spezielle kantenverstärkende Filter eingesetzt, auf die an dieser Stelle nicht näher eingegangen wird (siehe hierzu Kapitel 5.2). Ansonsten erfolgte die Binarisierung mit zwei unterschiedlichen Schwellenwertfiltern. Zum einen wurden die Bilder mit einer Grauwertschwelle von 80 und zum anderen mit einer Schwelle von 180 binarisiert (d.h. es wurden alle Punkte mit einem Grauwert zwischen 0=schwarz und 80 bzw. 180 in das Binärbild übernommen). Anschließend wurde anhand der Ausdehnung der erzeugten Objekte überprüft, inwieweit sich die beiden Ergebnisbilder voneinander unterscheiden. Bei deutlicher Unterscheidung wurde das mit dem 180er Schwellenwert erzeugte Bild zur weiteren Verarbeitung verwendet, da ansonsten helle Blattstrukturen wie Blattaufhellungen, weißliche Blätter oder besonders bei dicken Blättern durch die Scannertechnik entstehende helle Randabgrenzungen verloren gegangen wären. Bei geringem Unterschied zwischen den beiden Bildern (Normalfall) wurde der 80-er Schwellenwert verwendet, weil so die Blattränder schärfer abgegrenzt wurden.

Nach der Binarisierung wurde die größte zusammenhängende Punktmenge als Blattfläche ausgewählt. Um arte facte oder Störungen, bedingt durch die Bildaufnahme, zu erfassen, wurden Hohlfächen, die kleiner als ein bestimmter Anteil der Blattfläche waren, aufgefüllt und somit quasi zum Blatt hinzugezählt. Es sei darauf hingewiesen, daß größere Hohlfächen innerhalb der Binärbilder bei zusammengesetzten Blättern durchaus regulär auftreten können.

Nach der Binarisierung wurden die Bilder kopiert und auf eine einheitliche Größe maßstabsgetreu skaliert. Die verwendeten Skalierungsfaktoren ergaben sich zu:

$$x = \frac{1}{2} \begin{pmatrix} z_1 & z_2 \\ z_3 & z_4 \end{pmatrix} \quad (5.3.1)$$

$x$ : Skalierungsfaktor (in beide Richtungen gleich)

$z_{1,2}$ : gewünschte Bildbreite bzw. Bildhöhe [Pixel] (Vorgabe immer 500)

$z_{3,4}$ : reale Bildbreite bzw. Bildhöhe [Pixel] (je nach Blattgröße unterschiedlich)

Die Bildskalierung erfolgte, um einheitliche Voraussetzungen für den Einsatz bestimmter Bildbearbeitungsalgorithmen zu schaffen. Welche Bilder, ob skaliert oder unskaliert, zur weiteren Berechnung eingesetzt wurden, wird jeweils bei der Beschreibung der einzelnen Arbeitsschritte aufgeführt. Falls die entsprechenden Blattmerkmale mit den skalierten Bildern durchgeführt wurden, wurden sie - soweit sie nicht dimensionslos waren- am Ende wieder auf die Originalgröße umgerechnet.

### 5.3.2 Erkennung und Auswertung des Blattstieles und des Blattaufbaues

Zentraler Bestandteil eines Blatterkennungssystems ist die Identifikation des Blattstieles. Neben der botanischen Bedeutung der Blattstiellänge kommt diesem Aspekt besondere Bedeutung zu, weil in der Regel nur anhand des Blattstieles die Lage und Orientierung (z.B. oben, unten, Blattbasis, Blattspitze) des Objektes möglich ist. Da sehr viele botanische Merkmale von einer fest vorgegebenen Blatterorientierung ausgehen, ist es zwingend erforderlich, den Blattstiel auch in schwierigen Situationen (z.B. stark eingekerbte Blätter mit minimalem oder fast fehlendem Stielansatz) zu erkennen. Für weitere Bestimmungszwecke ist es ferner notwendig, zu unterscheiden, ob die Blattspreite aus mehreren Einzelblättchen zusammengesetzt ist oder nicht. Zur Lösung beider Probleme wurde ein Algorithmus, basierend auf morphologischen Operatoren, entwickelt.

Der Blattstiel eines Laubblattes wird bestimmt, indem das Blatt zuerst iterativ erodiert wird (bis der Blattstiel verschwindet) und anschließend dilatiert wird (vgl. auch Abb. 4.3.5). Wird die entstehende Punktmenge von der Ausgangsfläche abgezogen, ergeben sich Teilflächen, deren Größe dem Stiel entspricht. Darüberhinaus kann nach der Erosion anhand der Teilregionenbestimmung überprüft werden, ob es sich bei dem Blatt um ein zusammengesetztes oder einfaches Blatt handelt. Entscheidendes Kriterium zur Durchführbarkeit des aufgeführten Verfahrens ist die Kenntnis, ab welcher Erosion der Blattstiel nicht mehr vorhanden ist (d.h., welche Iterationstiefe verwendet werden soll). Im vorliegenden Fall wurde dieser Erosionsschritt mit der Längen- bzw. Breitenabnahme des Blattes der jeweiligen Erosionsstufe im Vergleich zur vorherigen Erosionsstufe berechnet. Das Blatt wurde bis zu einer vorgegebenen Grenze (Erosionsobergrenze) erodiert, und der Schritt, welcher die

maximale Abnahme der Blattlänge bzw. -breite verursachte, stellte die optimale Erosionstiefe dar.

Da bei zusammengesetzten Blattspreiten das oben beschriebene Verfahren nicht unmittelbar zum gewünschten Ziel führt (neben dem Blattstiel bleiben auch noch die Stiele der Einzelblätter als große Differenzflächen übrig), wurde der beschriebene Algorithmus um Operationen, die eine Skelettbildung voraussetzen, erweitert (ab Schritt ⑤). Die Blattstiellänge wurde am Ende direkt aus dem Abstand (Ausdehnung) der Blattstielpunktmenge und der bekannten Bildauflösung berechnet.

Der entwickelte Algorithmus wird im folgenden spezifiziert. Es gelten folgende spezielle Bezeichner (die übrigen Variablen und Indices sind innerhalb jeder Gleichung frei wählbar):

$G_{1 \dots 4}$ :	Zwischenergebnismengen
$m$ :	optimale Erosionstiefe
$W_1$ :	Ausgangsblatt (skaliertes Blatt)
$W_{2 \dots 4}$ :	Zwischenergebnisfläche
$W_5$ :	Blattstiel (Ergebnisfläche)
$Z$ :	Flächendifferenzenfolge

Konstanten (in Vorversuchen bestimmt):

$\lambda_1$ :	Erosionsobergrenze =	0,75
$\lambda_2$ :	Störungsanteil =	1000
$\lambda_3$ :	Umrechnungsfaktor von 150 dpi nach cm =	0,017

Berechnungsschritte:

① Berechnung der Flächendifferenzenfolge  $Z$  durch iterative Erosion der Ausgangsregion:

$Z := (z_1, z_2, z_3, \dots)$  mit

$$z_i = \Gamma_P \left( \Phi^R \left( \overbrace{\Omega_E^4(W_1)}^{i-1} \right) \right) - \Gamma_P \left( \Phi^R \left( \overbrace{\Omega_E^4(W_1)}^i \right) \right) \quad \text{für alle}$$

$$\Gamma_P \left( \Phi^R \left( \overbrace{\Omega_E^4(W_1)}^{i-1} \right) \right) \geq \lambda_1 \Gamma_P(\Phi^R(W_1))$$

② Bestimmung der optimalen Erosionstiefe  $m$ :

$$m := n \quad \text{mit} \quad z_n = \max_i(z_i)$$

③ Bearbeitung der Ausgangsregion mit der optimalen Erosionstiefe, Störungen eliminieren:

$$W_2 := \overbrace{\Omega_D^4 \left( \overbrace{\Omega_E^4(W_1)}^m \right)}^m$$

$$\mathbf{G}_1 := \left\{ H \mid H \in \Omega_T \left( \overbrace{\Omega_E^4(W_1)}^m \right), \Gamma_P(H) \geq \frac{\Gamma_P(W_1)}{\lambda_2} \right\}$$

Falls  $\Gamma_T(\mathbf{G}_1) > 1$ ,  
dann weiter bei ⑤.

④ Differenzfläche bestimmen, Stielfläche bestimmen:

$$\mathbf{G}_2 := \Omega_T(W_1 \setminus W_2)$$

$$W_5 \in \mathbf{G}_2 \quad \text{mit}$$

$$\Gamma_P(\Phi^O(W_5)) = \max_{H_i \in \mathbf{G}_2} \left( \Gamma_P(\Phi^O(H_i)) \right)$$

Weiter bei ⑤.

⑤ Skelettierung des Ausgangsblattes und Äste suchen, die nach außen ragen:

$$\mathbf{G}_2 := \Omega_T \left( \Omega_{V_s}(W_1) \setminus \Omega_D^8 \left( \Omega_{V_k}(W_1) \right) \right)$$

$$\mathbf{G}_3 := \left\{ H \mid H \in \mathbf{G}_2, \Gamma_P \left( H \setminus \Phi_H \left( \overbrace{\Omega_E^4(W_2)}^i \right) \right) > 0 \right\} \quad \text{mit}$$

$i =$  minimale ( $i \geq 0$ ) Anzahl Erosionen bis  $\Gamma_{\top}(\mathbf{G}_3) > 0$  (iterativ)

⑥ Bestimmung des Skelettstückes mit maximaler Ausdehnung:

$W_3 \in \mathbf{G}_3$  mit

$$\Gamma_{\text{R}}(\Phi^{\text{O}}(W_3)) = \max_{H_i \in \mathbf{G}_3} (\Gamma_{\text{R}}(\Phi^{\text{O}}(H_i)))$$

⑦ Entwicklung von Stielstücken aus dem Skelett und dem Ausgangsblatt:

$$W_4 := \overbrace{\Omega_{\text{D}}^4(W_3)}^{m+5} \cap W_1$$

$$\mathbf{G}_4 := \Omega_{\text{T}}((W_4 \setminus \Phi_{\text{H}}(W_2)) \cup (W_4 \cap \Phi_{\text{H}}(W_2)) \cap \Phi^{\text{O}}(W_3))$$

⑧ Auswahl der Stielfläche (zusammengesetztes Blatt):

$W_5 \in \mathbf{G}_4$  mit

$$\Gamma_{\text{P}}(W_5) = \max_{H_i \in \mathbf{G}_4} (\Gamma_{\text{P}}(H_i))$$

⑨ Blattart und Stiellänge bestimmen:

$$\varphi_2 = \begin{cases} 0 & \text{falls } \Gamma_{\top}(\mathbf{G}_1) = 1 \\ 1 & \text{sonst} \end{cases} \quad [-]$$

$$\varphi_{15} := \lambda_3 \Gamma_{\text{R}_1}(\Phi^{\text{O}}(W_5)) \quad [\text{cm}]$$

Abbildung 5.3.1 stellt den beschriebenen Algorithmus am Beispiel eines Laubblattes einer Moorbirke (*Betula pubescens*) graphisch dar. Teilbild I zeigt die im ersten Schritt entstehenden Rechteckflächen (schwarze Umrandung, Originalbild gelb) und die nach der letzten Iteration entstehende Blattfläche (grün). Teilbild II stellt die sich ergebenden Flächenabnahmen  $z_i$  zu Beginn des jeweiligen Erosionsschrittes  $i$  dar. Es wird deutlich, daß beim vierten Erosionsschritt die Flächenabnahme maximal ist und somit  $m = 4$  im obigen Algo-

rithmus gilt. Teilbild III zeigt die entstehenden Teilregionen (rote und schwarze Flächen), woraus sich als größte Ausdehnungsfläche (schwarz) der Stiel ergibt. Die Entscheidung, daß es sich bei dem Blatt um ein einfaches Blatt handelt, ist in diesem Fall eindeutig, da nach den 4 Erosionen nur eine zusammenhängende Fläche vorliegt.

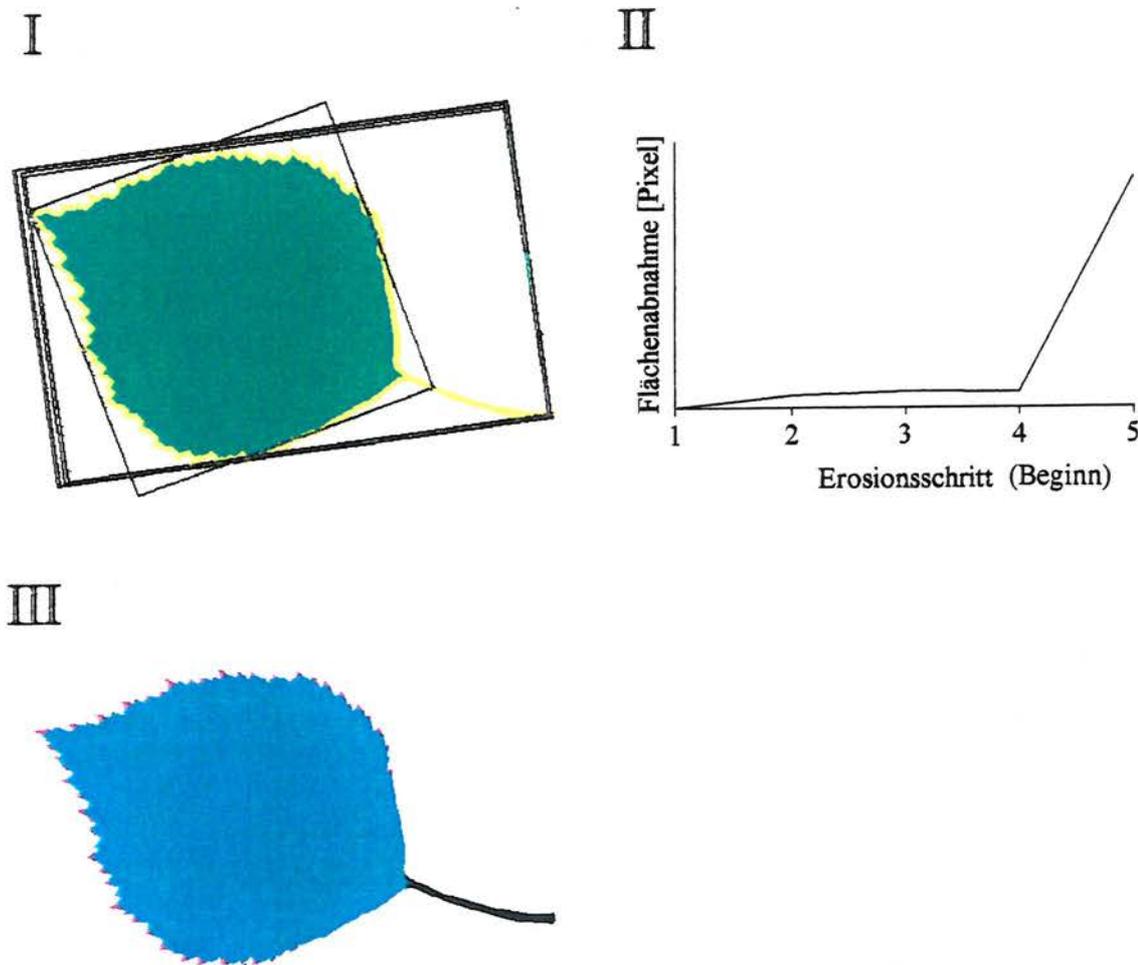
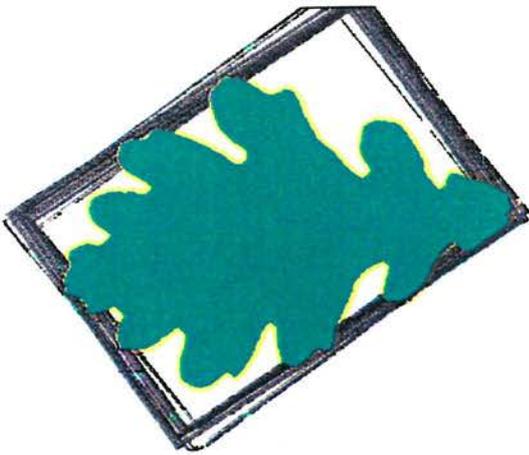


Abb. 5.3.1: Stiel- und Blatarterkennung einer Moorbirke (*Betula pubescens*)

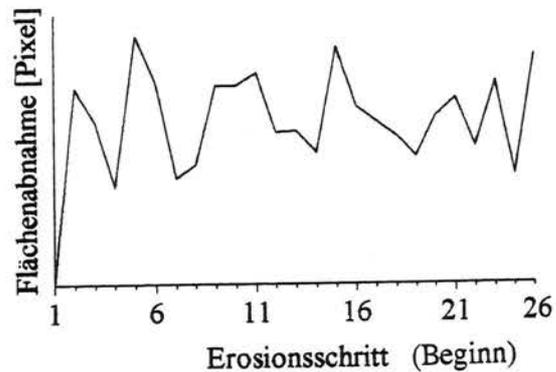
Abbildung 5.3.2 zeigt den Einsatz des Algorithmus bei der Stielerkennung eines schwach gestielten Eichenblattes (*Quercus robur*). Es gelten die gleichen Farbcodierungen und Teilbilderklärungen wie in Abb. 5.3.1. Man erkennt, daß 26 Erosionsschritte notwendig sind, um die Rechteckflächen auf unter 75 % zu reduzieren. Die maximale Flächenabnahme

erfolgt beim vierten Erosionsschritt. Teilbild II zeigt auch sehr deutlich, daß aufgrund der geringen Stiellänge und der starken Blatteinbuchtungen keine deutliche Abgrenzung möglich ist. Trotzdem wird der Blattstiel noch erkannt. Es ist zu beachten, daß die Flächenabnahme absolut (in Pixeln) gemessen wird und somit bei tieferen Erosionsschritten prozentual größere Abnahmen notwendig sind, um das Maximum zu erreichen oder zu überschreiten. Diese Tatsache wurde bewußt gewählt, da die Wahrscheinlichkeit einer Fehlinterpretation der Rechtecke mit zunehmender Iterationstiefe zunimmt.

I



II



III

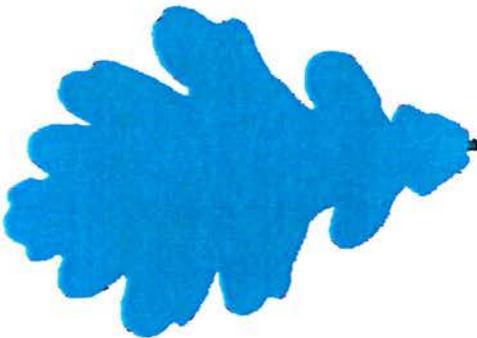


Abb. 5.3.2: Stiel- und Blatarterkennung einer kurzgestielten Stieleiche (*Quercus robur*)

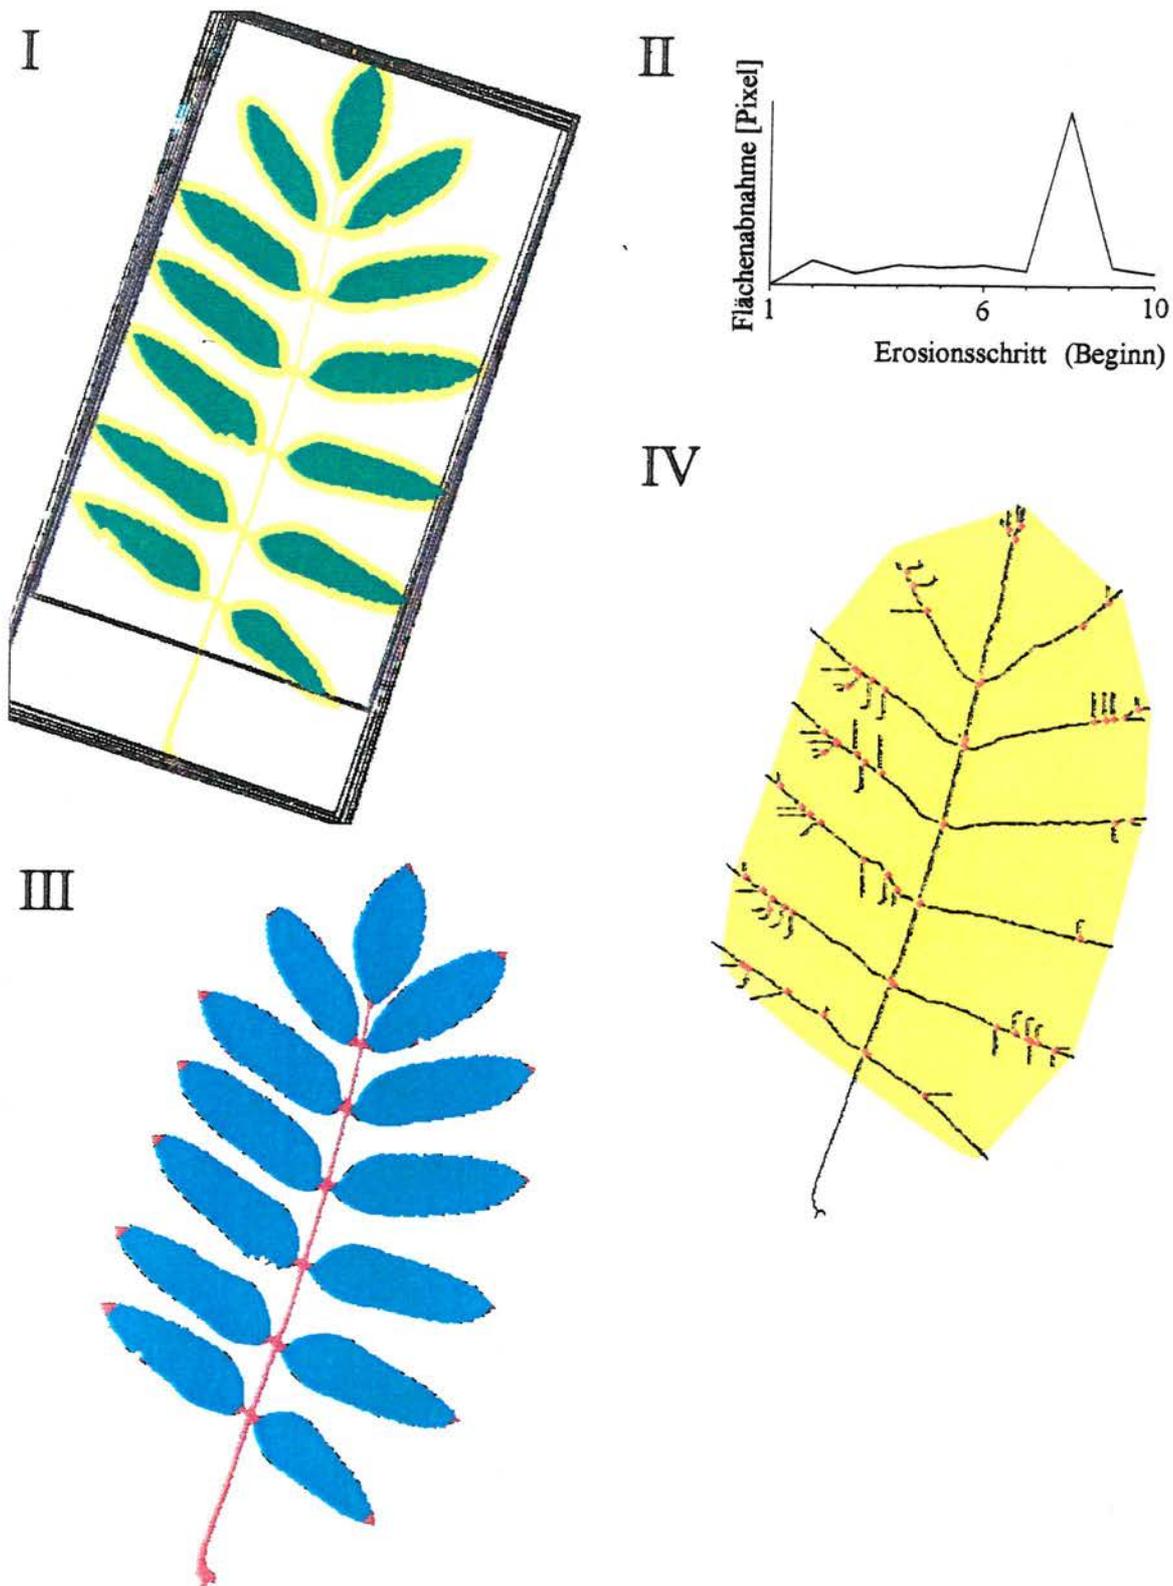


Abb. 5.3.3: Stiel- und Blatterkennung eines zusammengesetzten Blattes einer Eberesche (*Sorbus aucuparia*)

Abbildung 5.3.3 (Farbcodierung Teilbild I bis III siehe Abb. 5.3.1) zeigt den beschriebenen Algorithmus beim Einsatz zur Erkennung eines zusammengesetzten Blattes einer Eberesche (*Sorbus aucuparia*). Es wird deutlich, daß die Ergebnisse des Schrittes ④ nicht zum gewünschten Ziel führen würden (siehe Teilbild III, rote Flächen), da neben dem Blattstiel auch noch die Stiele der Einzelblätter als größte Ausdehnungsfläche übrigbleiben. Da die grünen voneinander getrennten Flächen deutlich ein zusammengesetztes Blatt anzeigen, wird die Fallunterscheidung in Schritt ③ wirksam. Teilbild IV zeigt deshalb die Stielsuche mit Hilfe der Skelettbildung. Die gelbe Fläche gibt die konvexe Hülle aus Schritt ⑤ wieder. Die roten Kästchen sind die vergrößerten Kreuzungspunkte im Skelett, die zur Trennung der einzelnen Äste und zur Suche der über die gelbe Fläche nach außen ragenden Skelettäste dienen. Abbildung 5.3.4 stellt Schritt ⑦ und ⑧ des Algorithmus dar. Teilbild I zeigt die Dilation des ausgewählten größten nach außen ragenden Skelettstückes (rot) und die Einschränkung auf die Blattfläche (blauer Bereich). Teilbild II zeigt die weitere Eingrenzung des genauen Stielansatzes mit Hilfe des Schnittes des oberen Stielteiles mit der gefüllten konvexen Hülle und des umschließenden Quadrates.

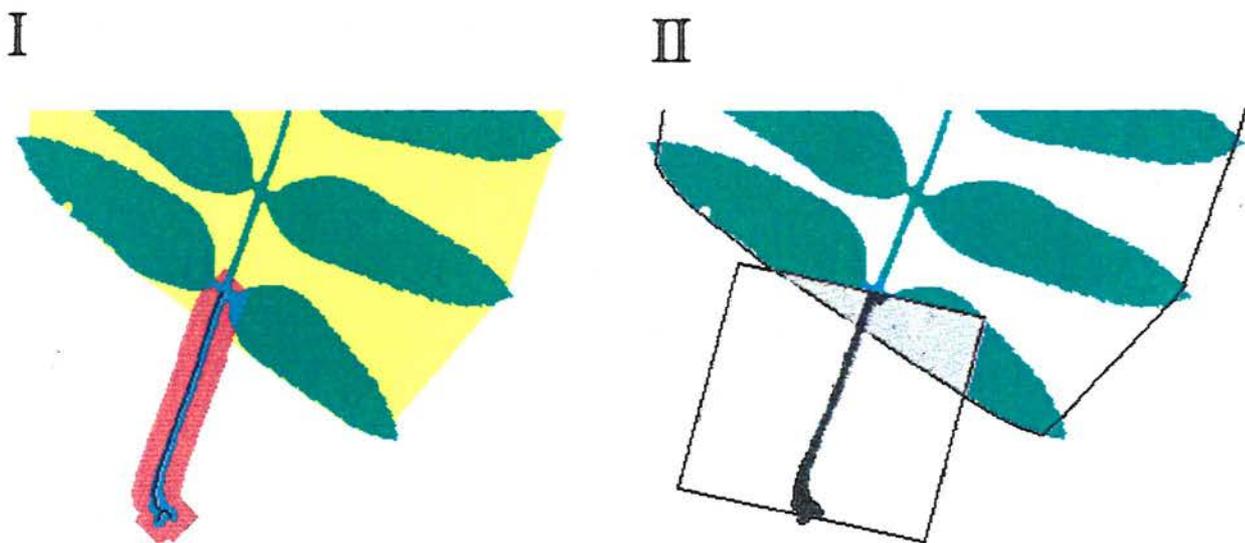


Abb. 5.3.4: Erkennung des Stielansatzpunktes des Blattes aus Abbildung 5.3.3

### 5.3.3 Erkennung und Auswertung der Spreitenbasis und der Spreitenspitze

Zur Erkennung und Unterscheidung der Spreitenbasis und der Spreitenspitze wurde ein Algorithmus entwickelt, der aufbauend auf den skalierten Blattbildern die einzelnen Blattbereiche nach eindeutig festgelegten Kriterien von einander abgrenzt. Die Unterteilung der Blattspreite in Basis, Spitze und mittleren Blattbereich erfolgte anhand einer vom Stielansatz bis zur Blattspitze verlaufenden Blattachse, die in definierte Abschnitte im Verhältnis 0,25 zu 0,5 zu 0,25 aufgeteilt wurde. Der Stielansatzpunkt wurde durch Schwerpunktberechnung der Schnittmenge von dilatierter Blattspreite und Stielfläche bestimmt. Die Blattspitze ergab sich aus dem entferntesten Punkt des Blattes vom Stielansatzpunkt (siehe ❶). Die Trennungslinien zwischen den einzelnen Blattabschnitten wurden senkrecht zur Blattachse gebildet. Nach Separation der einzelnen Blattabschnitte wurden die Merkmalsparameter  $\varphi_{16} - \varphi_{22}$  berechnet, wobei bei zusammengesetzten Blättern die konvexen Hüllen der Blattabschnitte als Eingangsobjekte dienten (siehe Fallabfrage in Algorithmusteil ❷). Der genaue Algorithmus definiert sich wie folgt:

Spezielle Bezeichner:

$W_1$ : skaliertes Blatt

$W_2$ : Blattstiel (skaliertes Blatt)

$W_3$ : Blattspreite

$W_4$ : Stielansatzpunkt

$W_5$ : Blattspitzenendpunkt

$W_8$ : Spreitenbasis

$W_9$ : Spreitenspitze

$W_{6, 7, 10 \dots 14}$ : Zwischenergebnisflächen

$r$ : halbe Länge der Blattachse

$s$ : Mittelpunkt der Blattachse

$x_i, y_i$ : Rechteckradien ( $i=1$  für Radien in Blattachsenausrichtung)

$\theta$ : Ausrichtungswinkel der Blattachse

Festgelegte Konstanten:

$\lambda_{1,2}$ : Bildhöhe bzw. -breite des skalierten Bildes (siehe Kap. 5.3.1)

$\lambda_3$ : Anteil der Blattbasis und der Blattspitze = 0,25

Berechnungsschritte:

❶ Bestimmung der Blattspreite und des Stielansatzpunktes und des Blattspreitenendpunktes:

$$W_3 := W_1 \setminus W_2$$

$$W_4 := \Phi_S(W_2 \cap \Omega_D^4(W_3))$$

$$W_5 := \Phi_S(\Omega_{V_r}(\Phi_K(n, W_4)) \cap W_3) \quad \text{mit}$$

$$\Omega_{V_r}(\Phi_K(n, W_4)) \cap W_3 \neq \{ \} \quad \text{und} \quad \Omega_{V_r}(\Phi_K(n+1, W_4)) \cap W_3 = \{ \}$$

❷ Bestimmung der Blattachsenparameter:

$$r := \Gamma_R(W_4 \cup W_5)$$

$$\mathbf{s} := \Phi_S(W_4 \cup W_5)$$

$$\theta := \Gamma_W(W_4 \cup W_5)$$

❸ Bestimmung des mittleren Blattausschnittes:

$$W_6 := \Phi^R(W_1)$$

$$W_7 := \Phi_R\left(\left(\begin{array}{c} \lambda_1 + \lambda_2 \\ r(1 - 2\lambda_3) \end{array}\right), \mathbf{s}, \theta + \frac{\pi}{2}\right)$$

❹ Bestimmung der Spreitenbasis und der Spreitenspitze:

$$W_8 := H \cap W_3 \quad \text{mit}$$

$$H \in \Omega_T(W_6 \setminus W_7) \quad \text{und} \quad H \cap W_4 \neq \{ \}$$

$$W_9 := ((W_6 \setminus W_7) \setminus W_8) \cap W_3$$

Falls Blatt zusammengesetzt ( $\varphi_2 = 1$ , siehe Kap. 5.3.2),  
dann  $W_{10} := \Phi_H(W_8)$ ,  $W_{11} := \Phi_H(W_9)$  und  $W_{12} := \Phi_H(W_3)$ ,  
sonst  $W_{10} := W_8$ ,  $W_{11} := W_9$  und  $W_{12} := W_3$ .

⑤ Bestimmung der umschließenden Rechtecke und Radien in Blattachsenausrichtung:

$$W_{13} := \Phi^R(W_{11}, \theta)$$

$$W_{14} := \Phi^R(W_{10}, \theta)$$

$$x_i := \Gamma_{R_i}(W_{13}) \quad \text{mit } i = 1 \text{ und } 2$$

$$y_i := \Gamma_{R_i}(W_{14}) \quad \text{mit } i = 1 \text{ und } 2$$

⑥ Bestimmung der Blattparameter:

$$\varphi_{16} := \frac{x_1}{x_2} \quad [ - ]$$

$$\varphi_{17} := \Gamma_H(W_9) \quad [ - ]$$

$$\varphi_{18} := \frac{\Gamma_P(W_{11})}{\Gamma_P(W_{13})} \quad [ - ]$$

$$\varphi_{19} := \frac{\Gamma_P(W_{11})}{\Gamma_P(W_{12})} \quad [ - ]$$

$$\varphi_{20} := \frac{y_1}{y_2} \quad [ - ]$$

$$\varphi_{21} := \Gamma_H(W_8) \quad [ - ]$$

$$\varphi_{22} := \frac{\Gamma_P(W_{10})}{\Gamma_P(W_{14})} \quad [ - ]$$

Abbildung 5.3.5 demonstriert die Vorgehensweise an drei Beispielen. Die Mittelachse ist schwarz eingezeichnet. Die Ausdehnung (Länge zu Breite) der extrahierten Spreitenspitze bzw. der Spreitenbasis ergibt sich aus den roten Rechtecken, die an den Blattachsen orientiert ausgerichtet sind. Die jeweiligen konvexen Hüllen sind grau plus blau.

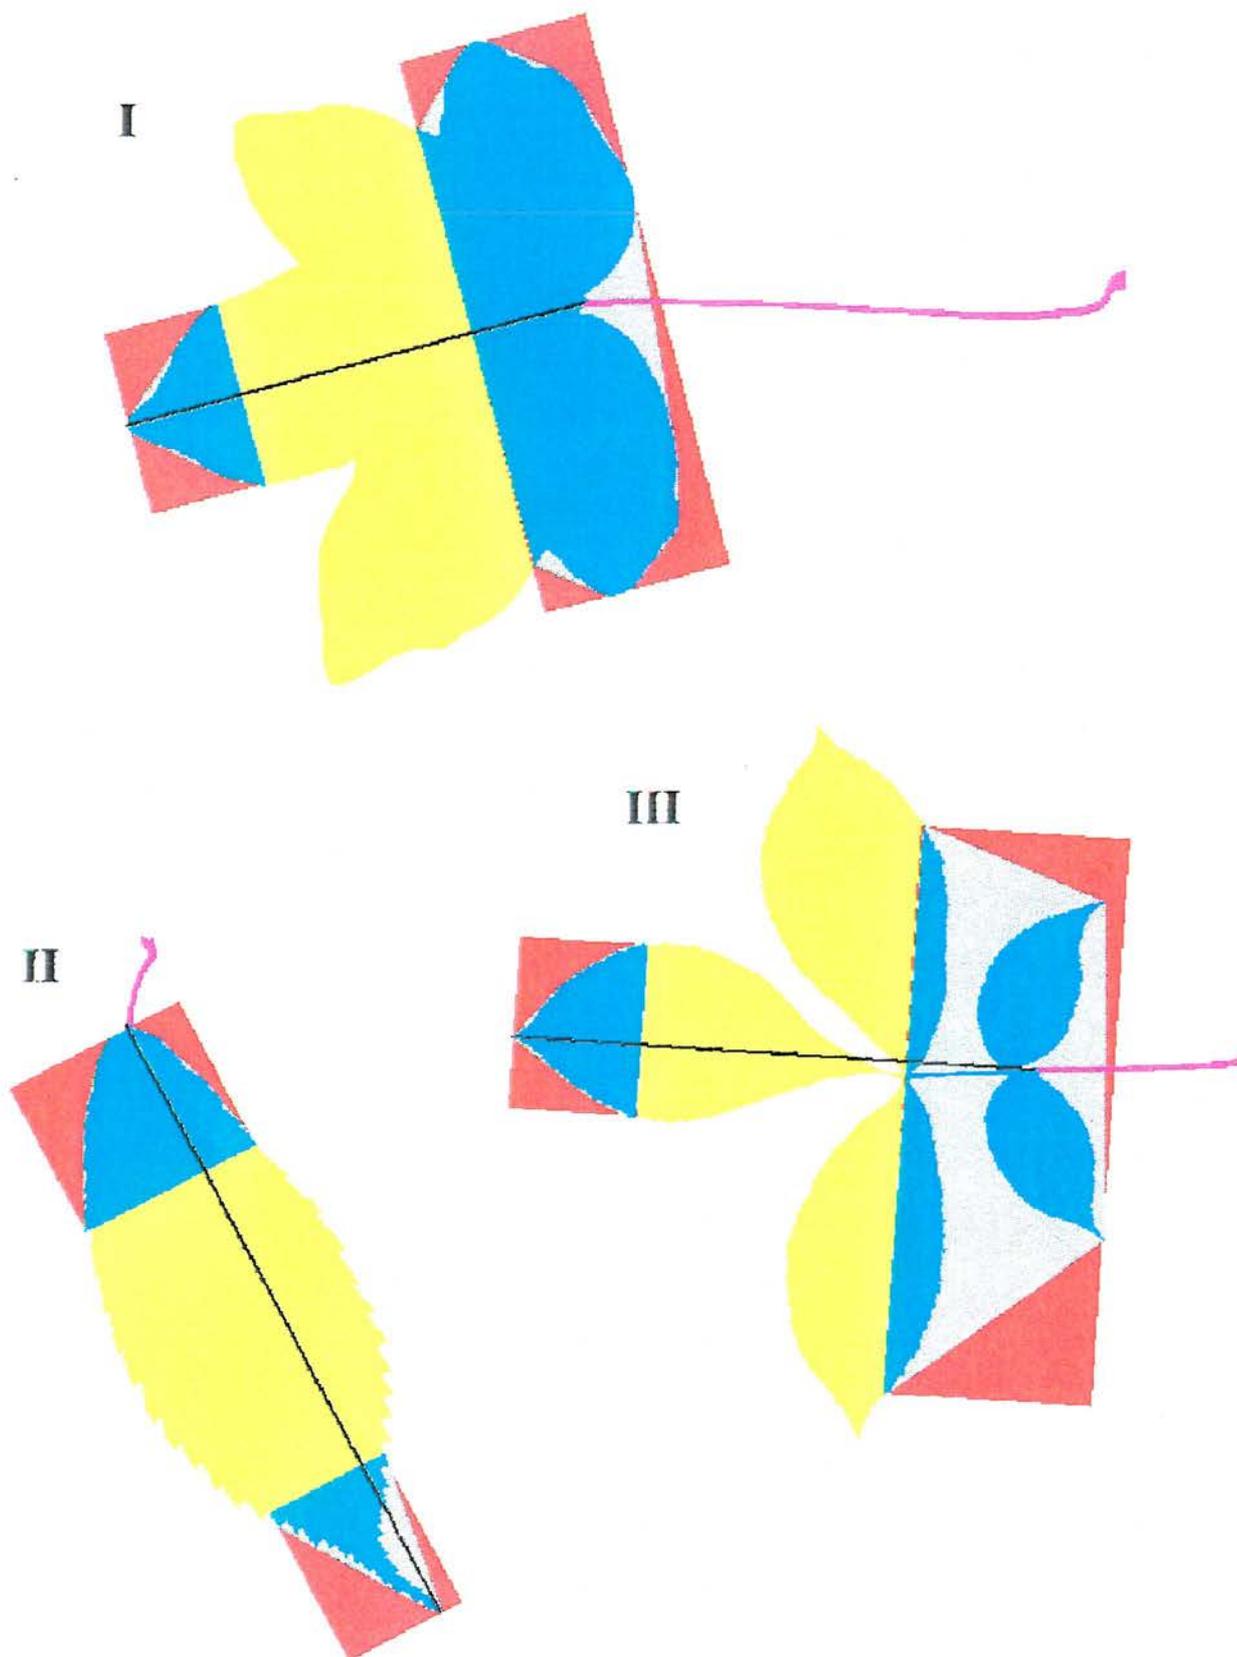


Abb. 5.3.5: Bestimmung der Parameter der Spreitenbasis und der Spreitenspitze an drei Beispielen (I: *Acer campestre*, II: *Acer carpinifolium*, III: *Carya cordiformis*)

### 5.3.4 Erkennung und Auswertung der Blattspreite

Die Ausprägung der Blattspreite ist ein wesentliches Unterscheidungskriterium zur Differenzierung der Laubbaumarten. Die unspezifischen Formparameter Konvexität, Kompaktheit, Rundheit und die Pixelfläche (Blattfläche) lassen sich leicht mit den zur Verfügung stehenden Verhältniszahlen und Operatoren bestimmen. Die Berechnung der Länge zu Breite und die Bestimmung der Eckigkeit berücksichtigt ähnlich wie in Kapitel 5.3.2 die Ausrichtung der Blattachse. Zur Berechnung der Elliptizität wurde eine Vergleichsellipse gebildet, die das gleiche Seitenverhältnis, die gleiche Fläche und den gleichen Schwerpunkt hat wie die Blattspreite (oder die konvexe Hülle der Blattspreite).

Bei einigen Parametern wurde wie bei der Bestimmung der Formparameter der Spreitenbasis und Spreitenspitze bei zusammengesetzten Blättern die konvexe Hülle der Blattspreite genutzt. Da die aufgeführten Formparameter unabhängig von der Bildgröße sind, wurden - außer bei der Bestimmung der Blattfläche - immer skalierte Blattbilder verwendet. Es ergaben sich folgende Berechnungen:

Spezielle Bezeichner:

$W_1$ : unskaliertes Originalblatt

$W_2$ : skaliertes Blatt

$W_3$ : Blattstiel (skaliertes Blatt)

$W_4$ : Blattspreite

$W_5$ : konvexe Hülle der Blattspreite

$W_6$ : umschließendes Rechteck in Blattachsenausrichtung

$W_7$ : auf die Blattbreite, -länge und -fläche normierte Ellipse

$W_8$ : Umschließender Kreis mit gleichem Flächenschwerpunkt

$s$ : Flächenschwerpunkt der Blattspreite

$v$ : Mittelpunkt des Blatt-Umkreises

$\gamma$ : Ausrichtung der Blattspreite

$\theta$ : Ausrichtungswinkel der Blattachse (siehe Kapitel 5.3.3)

Berechnungsschritte:

① Bestimmung der Blattbreite bzw. der Analysefläche:

$$W_4 := W_2 \setminus W_3$$

Falls Blatt zusammengesetzt ( $\varphi_2 = 1$ , siehe Kap. 5.3.2),  
dann  $W_5 := \Phi_H(W_4)$ , sonst  $W_5 := W_4$ .

② Bestimmung des umschließenden Rechteckes, der speziellen Ellipse und des Umkreises:

$$W_6 := \Phi^R(W_5, \theta)$$

$$W_7 := \Phi_E(\mathbf{r}, \mathbf{s}, \gamma) \quad \text{mit}$$

$$\mathbf{s} = \Phi_S(W_5), \quad \frac{r_1}{r_2} = \frac{\Gamma_{R_1}(W_5)}{\Gamma_{R_2}(W_5)}, \quad \gamma = \Gamma_W(W_5) \quad \text{und}$$

$$\Gamma_P(W_7) = \Gamma_P(W_5)$$

$$W_8 := \Phi^K(W_5, \mathbf{v}) \quad \text{mit} \quad \mathbf{v} = \Phi_S(W_5)$$

③ Bestimmung der Blattparameter:

$$\varphi_5 := \Gamma_P(W_1) \quad [\text{Pixel}] \qquad \varphi_6 := \frac{\Gamma_{R_1}(W_6)}{\Gamma_{R_2}(W_6)} \quad [-]$$

$$\varphi_7 := \Gamma_H(W_4) \quad [-] \qquad \varphi_8 := \frac{(\Gamma_U(W_4))^2}{4\pi \Gamma_P(W_4)} \quad [-]$$

$$\varphi_9 := \frac{\Gamma_P(W_5)}{\pi (\Gamma_R(W_8))^2} \quad [-] \qquad \varphi_{10} := \frac{\Gamma_P(W_5 \setminus W_7)}{\Gamma_P(W_5)} \quad [-]$$

$$\varphi_{11} := \frac{\Gamma_P(W_5)}{\Gamma_P(W_6)} \quad [-]$$

Die Abbildungen 5.3.6 und 5.3.7 demonstrieren die Vorgehensweise an drei Beispielen. Bei zusammengesetzten Blättern wird die konvexe Hülle der Blattspreite (ohne Stiel) zur Bestimmung der Länge zu Breite ( $\varphi_6$ ), der Rundheit ( $\varphi_9$ ), der Elliptizität ( $\varphi_{10}$ ) und der Eckigkeit ( $\varphi_{11}$ ) eingesetzt. Im einzelnen gilt folgende Farbcodierung:

Blattstiel = violett, Blattspreite = gefüllte schwarze Kontur bzw. Umrißlinie; konvexe Hülle der Blattspreite = grau; umschließendes Rechteck in Blattachsenausrichtung = rot; spezielle Elipse = weiß plus gelb; Umkreis und Schwerpunkt = grün.

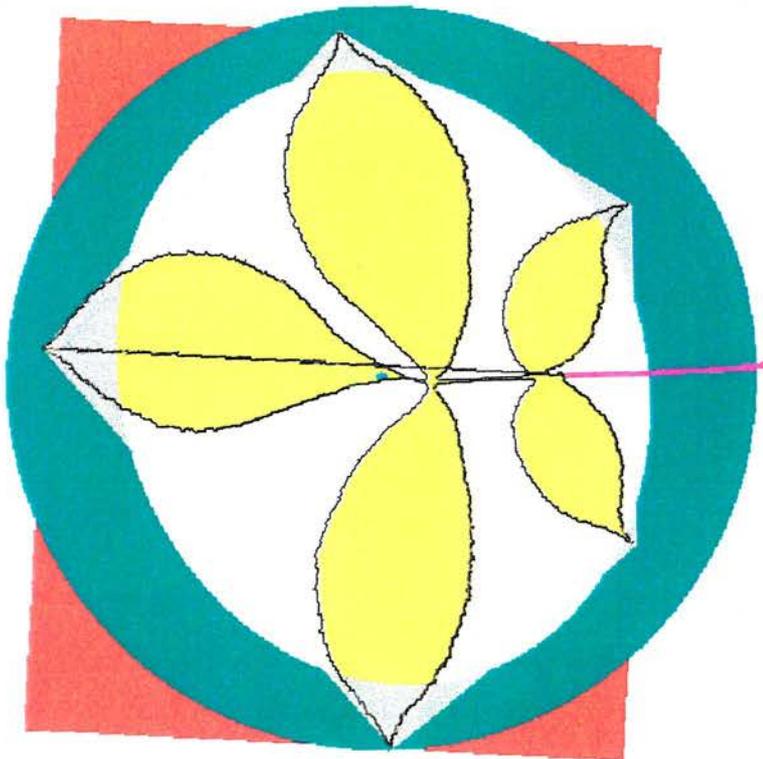


Abbildung 5.3.6: Flächen zur Berechnung der Spreitenparameter bei einem zusammengesetzten Blatt (*Carya cordiformis*)

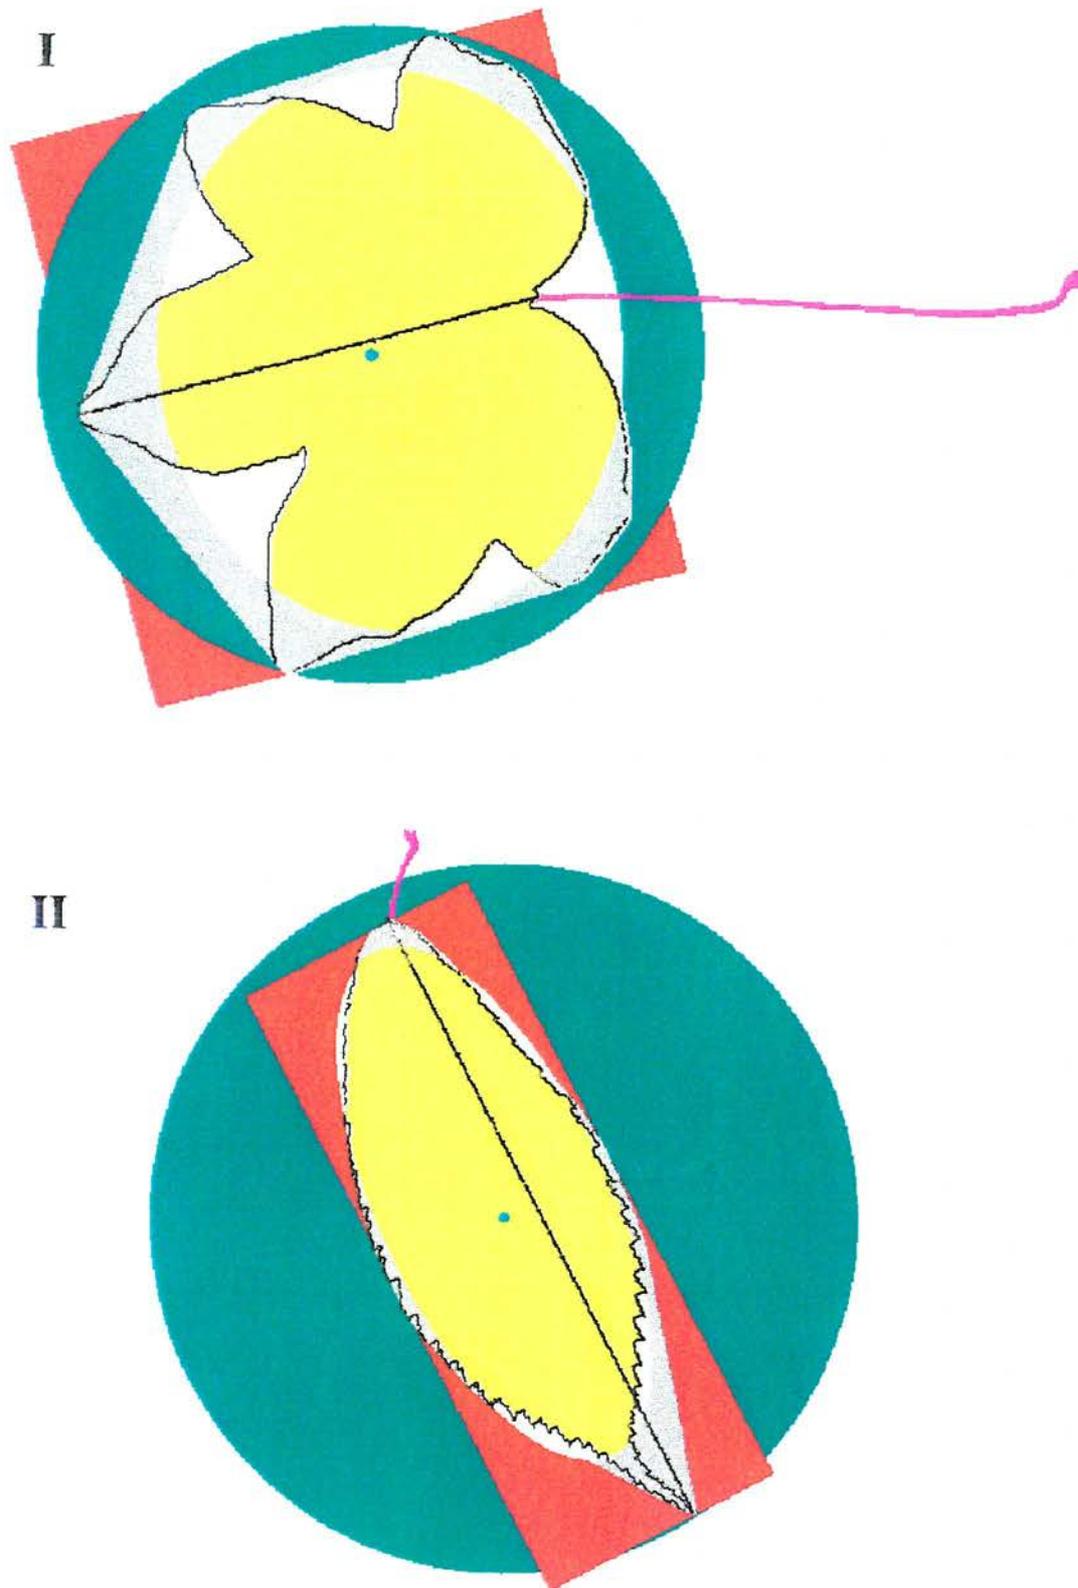


Abbildung 5.3.7: Flächen zur Berechnung der Spreitenparameter bei einfachen Blättern

(I: *Acer campestre*, II: *Acer carpinifolium*)

### 5.3.5 Erkennung und Auswertung der Einzelblättchen

Zur Bestimmung der Anzahl der Einzelblätter wurde ein Algorithmus entwickelt, der die Erkennung von Einzelblättchen eines Laubblattes durchführt, indem das Gesamtblatt in einzelne Objekte getrennt wird. Ein Objekt wird als getrenntes Einzelobjekt erkannt, wenn seine Konvexität einen bestimmten Grenzwert überschreitet, d.h. wenn das Objekt nur einen geringen Flächenanteil an Einbuchtungen (mögliche Überlappungsstellen) aufweist. Hierzu wird das Objekt aus einer Ausgangsmenge entnommen und auf Konvexität getestet. Erfüllt das Objekt das Konvexitätskriterium, wird es einer Ergebnismenge hinzugefügt. Wird das Konvexitätskriterium nicht erfüllt, wird versucht, das Objekt durch Erosionen in mehrere Teilobjekte zu zerlegen, die dann wieder in der Ausgangsmenge abgelegt werden. Kann das Objekt trotz intensiver Erosionen nicht in zwei oder mehrere Objekte getrennt werden, wird das Erosionsverfahren als gescheitert betrachtet. Stattdessen wird versucht, das Ausgangsobjekt mit einem geometrisch orientierten Schnitt (einer Trennlinie) zu zerlegen. Die evtl. resultierenden Ergebnisflächen werden erneut in der Ausgangsdatenbank abgelegt. Der Schnitt erfolgt an der tiefsten Einbuchtung und orientiert sich an verschiedenen Skelettpunkten oder am Flächenschwerpunkt der Außenkante der entsprechenden Einbuchtung.

Zu Beginn des Bearbeitungsverfahrens wird die Ausgangsmenge mit dem zu analysierenden Objekt (Binärbild, erodiert, bis der Stiel entfernt ist) initialisiert. Anschließend wird das gesamte Verfahren so lange wiederholt, bis keine Objekte mehr in der Ausgangsmenge vorhanden sind. Die Anzahl der Einzelobjekte der Ergebnismenge entspricht dann der Anzahl der vorliegenden Einzelblättchen der Blattspreite.

Das Gelingen des Algorithmus hängt im wesentlichen von der richtigen Wahl des Konvexitätskriteriums ab. Handelt es sich bei den überlappenden Einzelobjekten um konvexe Objekte, kann das Konvexitätskriterium relativ hoch angesetzt werden, da jede Einbuchtung durch Überlappung verursacht sein muß. Da bei zusammengesetzten Blättern aber die Einzelobjekte (Einzelblätter) selbst auch hochgradig unkonvex sein können, wurde das Konvexitätskriterium als eine flexible Funktion gebildet, die durch zwei Grenzwerte und die momentane Flächengröße definiert ist (vgl. Abb. 5.3.8).

Folglich ergeben sich 5 Modellparameter, mit denen der Algorithmus an die jeweiligen Anforderungen angepaßt werden kann: 1. Der Anteil der Ausgangsfläche, bis wohin erodiert werden kann, um das Objekt zu teilen (Erosionsobergrenze). Anschließend wird das ursprüngliche Objekt mit dem Schnittverfahren bearbeitet. 2. Der Teil der Gesamtblattfläche, ab der die Konvexitätsobergrenze als Konvexitätskriterium gilt (Blättchenanteil). 3. Der obere Grenzwert des Konvexitätskriteriums (Konvexitätsobergrenze). Liegt der zu bewertende Flächenanteil oberhalb es Blättchenanteils, wird der obere Grenzwert als Konvexitätskriterium verwendet. 4. Der Teil an der Gesamtblattfläche, bis der die Konvexitätsuntergrenze als Konvexitätskriterium gilt (Störungsanteil). Alle Flächen, die kleiner als der Störungsanteil sind, werden als nicht weiter interpretierbare Bildstörungen bewertet. 5. Der untere Grenzwert des Konvexitätskriteriums (Konvexitätsuntergrenze). Ist der zu bewertende Flächenanteil gleich dem Störungsanteil, wird der untere Grenzwert als Konvexitätskriterium verwendet. Liegt er zwischen dem Störungs- und Blättchenanteil, wird linear interpoliert (vgl. Abb. 5.3.8). Da die Konvexitätsuntergrenze deutlich unterhalb der Obergrenze liegt, kann bei zunehmender Erosion (und damit auch Objektverfälschung) das Konvexitätskriterium immer leichter erfüllt werden und es sind somit keine weiteren Erosionen oder Schnittmaßnahmen mehr notwendig. Eine übermäßige Objektverfälschung wird hierdurch verhindert.

Der entwickelte Algorithmus mit den speziellen Bezeichnern und Konstanten wird wie folgt definiert.

Spezielle Bezeichner:

$G_1$ :	Bearbeitungsobjekte (Ausgangsmenge)
$G_2$ :	konvexe Ergebnisobjekte (Ergebnismenge)
$G_5$ :	nach Erosion entstandene Teilflächen
$G_8$ :	nach Flächenschnitt entstandene Teilflächen
$G_{3, 4, 6, 7}$ :	Zwischenergebnismengen
$V$ :	Flächenfolge
$j$ :	Index des ausgewählten Flächenobjektes $V_j$
$V_j$ :	Flächenobjekt der Flächenfolge $V$
$W_1$ :	Blatt ohne Stiel (skaliert), (Punktmenge)

$W_2$ :	vollständiges Blatt (skaliert), (Punktmenge)
$W_3$ :	aktuelles Bearbeitungsobjekt
$W_5$ :	erodiertes Bearbeitungsobjekt
$W_8$ :	Außenkante der Einbuchtungsfläche
$W_{9, 10}$ :	Start- und Endpunkte der jeweiligen Schnittlinie
$W_{13}$ :	Schnitt- bzw. Trennlinie
$W_{14}$ :	geschnittenes Bearbeitungsobjekt
$W_{4, 6, 7, 11, 12}$ :	Zwischenergebnisflächen
$\zeta$ :	Konvexitätskriterium

In Vorversuchen wurden optimale Konstanten bestimmt. Sie ergeben sich zu:

$\lambda_1$ :	Konvexitätsuntergrenze	=	0,30
$\lambda_2$ :	Konvexitätsobergrenze	=	0,85
$\lambda_3$ :	Störungsanteil	=	1000
$\lambda_4$ :	Blättchenanteil	=	15
$\lambda_5$ :	Erosionsobergrenze	=	0,75

Bearbeitungsschritte:

❶ Initialisierung der Ausgangsmenge, Ergebnismenge, Zwischen- und Laufvariablen:

$$\mathbf{G}_1 := \{ \}, \mathbf{G}_2 := \{ \}, \mathbf{G}_3 := \Omega_T(W_1), \mathbf{G}_4 := \{ \}, W_{13} := \{ \}, j := 0$$

❷ Bearbeitung der Ausgangsmenge und Ergebnismenge, Bearbeitungselemententnahme:

$$\mathbf{G}_1 := \mathbf{G}_1 \cup \mathbf{G}_3, \mathbf{G}_2 := \mathbf{G}_2 \cup \mathbf{G}_4.$$

Falls  $\mathbf{G}_1 = \{ \}$ , dann weiter bei ❸.

$$W_3 \in \mathbf{G}_1, \mathbf{G}_1 := \mathbf{G}_1 \setminus W_3, W_4 := W_3$$

❸ Überprüfung des Konvexitätskriteriums (vgl. Abbildung 5.3.8):

$$\zeta := \begin{cases} \lambda_1 & \text{falls } x \leq \lambda_1 \\ \lambda_2 & \text{falls } x > \lambda_2 \\ x & \text{sonst} \end{cases} \quad \text{mit}$$

$$x = \lambda_1 + \frac{\lambda_4(\Gamma_P(W_4)\lambda_3 - \Gamma_P(W_2))(\lambda_2 - \lambda_1)}{\Gamma_P(W_1)\lambda_3 - \Gamma_P(W_2)\lambda_4}$$

Falls  $\Gamma_H(W_4) \geq \zeta$ , dann  $\mathbf{G}_3 := \{\}$ ,  $\mathbf{G}_4 := \{W_4\}$   
und weiter bei ②.

④ Erosion der Fläche, Flächenaufteilung und Test der neuen Flächen:

$$W_5 := \Omega_E^4(W_4)$$

$$\mathbf{G}_5 := \left\{ H \mid H \in \Omega_T(W_5), \Gamma_P(H) \geq \frac{\Gamma_P(W_2)}{\lambda_3} \right\}$$

Falls  $\Gamma_T(\mathbf{G}_5) = 0$ , dann  $\mathbf{G}_3 := \{\}$ ,  $\mathbf{G}_4 := \{\}$   
und weiter bei ②.

Falls  $\Gamma_T(\mathbf{G}_5) = 1$  und  $\Gamma_P(W_6) \geq \lambda_5 \Gamma_P(W_3)$ ,  
dann  $W_4 := W_5$  und weiter bei ③.

Falls  $\Gamma_T(\mathbf{G}_5) > 1$ , dann  $\mathbf{G}_3 := \mathbf{G}_5$ ,  $\mathbf{G}_4 := \{\}$   
und weiter bei ②.

⑤ Fläche zerschneiden (Trennlinie einfügen):

⑤.① Rand der konvexen Hülle und Einbuchtungsflächen bestimmen:

$$W_7 := \Omega_{V_r}(\Omega_H(W_3))$$

$$\mathbf{G}_6 := \left\{ H \mid H \in \Omega_T(\Omega_H(W_3) \setminus \Omega_F(W_3)), \Gamma_P(H) \geq \frac{\Gamma_P(W_2)}{\lambda_3} \right\}$$

**5.2** Nach Einbuchtungstiefe geordnete Flächenfolge  $\mathbf{V}$  bestimmen:

$\mathbf{V} := (V_1, V_2, V_3, \dots)$  mit

$$V_i \in \mathbf{G}_6 \text{ und } \Gamma_A \left( V_i \setminus \overbrace{\Omega_D^4(H_i)}^n, H_i \right) \geq \Gamma_A \left( V_{i+1} \setminus \overbrace{\Omega_D^4(H_{i+1})}^n, H_{i+1} \right) \text{ mit}$$

$$H_i = (V_i \cap W_7), \quad V_i \setminus \overbrace{\Omega_D^4(H_i)}^n \neq \{ \} \text{ und } V_i \setminus \overbrace{\Omega_D^4(H_i)}^{n+1} = \{ \}$$

**5.3** Einbuchtungsfläche  $V_j$  auswählen, Endpunkte der Skelettäste bestimmen:

$$j := j + 1$$

$$W_8 := V_j \cap W_7$$

$$\mathbf{G}_7 := \Omega_T \left( \Omega_{V_e} \left( \Omega_{V_s} (V_j) \setminus \Omega_D^4 \left( \Omega_{V_k} (V_j) \right) \right) \right)$$

Falls  $\Gamma_P \left( \Omega_{V_s} (V_j) \right) < 2$ , dann weiter bei **5.3**.

Falls  $\Omega_{V_k} (V_j) = \{ \}$ , dann weiter bei **5.5**.

**5.4** Ausrichtungspunkte der Schnittlinie bestimmen (Verfahren mit Kreuzungspunkten):

$W_9 \in \mathbf{G}_7$  mit

$$\Gamma_A(W_9, W_8) = \max_{H \in \mathbf{G}_7} (\Gamma_A(H, W_8))$$

$W_{10} \in \mathbf{G}_7$  mit

$$W_{10} = H \setminus W_9 \text{ und } W_9 \subseteq H \text{ mit}$$

$$H \in \Omega_T \left( \Omega_{V_s} (V_j) \setminus \Omega_D^4 \left( \Omega_{V_k} (V_j) \right) \right)$$

$$W_{11} := W_9$$

Falls  $W_{10} = \{ \}$ , dann weiter bei **5.3**,

sonst weiter bei **5.6**.

**5.5** Ausrichtungspunkte der Schnittlinie bestimmen (Verfahren ohne Kreuzungspunkte):

$$W_9 := \Omega_S \left( \overbrace{\Omega_D^4(W_8)}^n \right) \quad \text{mit}$$

$$V_i \setminus \overbrace{\Omega_D^4(W_8)}^n \neq \{ \} \quad \text{und} \quad V_i \setminus \overbrace{\Omega_D^4(W_8)}^{n+1} = \{ \}$$

$$W_{10} := \Omega_S(W_8)$$

$$W_{11} := W_9$$

**5.6** Schnittlinie bestimmen ( $W_{11}$  = Linienendpunkt,  $W_{12}$  = vorheriger Linienendpunkt):

$$W_{12} := W_{11}$$

$$W_{11} := \{(v_1, v_2)\} \quad \text{mit}$$

$$v_i = \begin{cases} h_i + 1 & \text{falls } z_k = 0, z_i > 0 \\ h_i - 1 & \text{falls } z_k = 0, z_i < 0 \\ h_i + 1 & \text{falls } |z_i| \geq |z_k| > 0, z_i > 0 \\ h_i - 1 & \text{falls } |z_i| \geq |z_k| > 0, z_i < 0 \\ h_i + 1 & \text{falls } |z_i| \geq |z_k| > 0, x_i - h_i > 1,5 \\ h_i - 1 & \text{falls } |z_i| \geq |z_k| > 0, x_i - h_i < 1,5 \\ h_i & \text{sonst} \end{cases} \quad \text{mit}$$

$$h \in W_{12}, \quad k \in \{1, 2\}, \quad k \neq i, \quad x_i = \frac{z_i}{z_k} (v_k - z_k) + z_i \quad \text{mit}$$

$$z_l = s_l - w_l \quad \text{mit}$$

$$s \in W_9 \quad \text{und} \quad w \in W_{10}$$

$$W_{13} := W_{13} \cup \Omega_D^4(W_{12}) \cup \Omega_D^4(W_{11})$$

Falls  $W_{12} \in W_3$  oder  $W_{11} \notin W_3$ ,  
dann weiter bei **5.6**.

5.7 Trennlinie aus der Fläche löschen, Flächenaufteilung, Test der neuen Flächen:

$$W_{14} := W_3 \setminus W_{13}$$

$$G_8 := \left\{ H \mid H \in \Omega_T(W_{14}), \Gamma_P(H) \geq \frac{\Gamma_P(W_2)}{\lambda_3} \right\}$$

Falls  $\Gamma_T(G_8) \leq 1$ , dann  $G_3 := \{W_5\}$ ,  $G_4 := \{\}$

und weiter bei 2.

Falls  $\Gamma_T(G_8) > 1$ , dann  $G_3 := G_8$ ,  $G_4 := \{\}$

und weiter bei 2.

6 Bestimmung der Anzahl der Einzelblätter:

$$\varphi_3 := \Gamma_T(G_2) \quad [-]$$

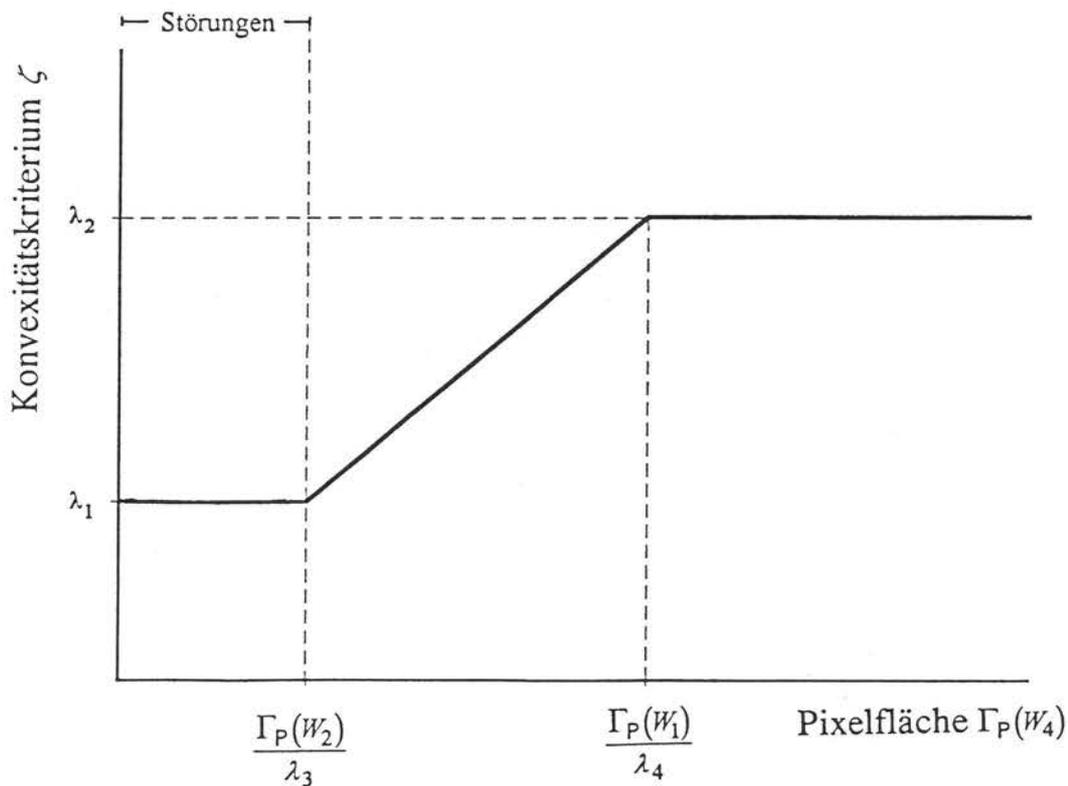


Abb. 5.3.8: Konvexitätskriterium  $\zeta$  in Abhängigkeit von der Pixelfläche  $\Gamma_P(W_4)$

Die Blattanzahlberechnung wurde für alle Blätter mit den aufgeführten Konstanten durchgeführt. Die Abbildungen 5.3.9, 5.3.10 und 5.3.11 verdeutlichen das beschriebene Verfahren an zwei Beispielen.

Es gelten folgende Farbcodierungen:

- Grün: erodiertes Ausgangsblatt  $W_1$
- Schwarz: Region (Objekt) in der Ergebnismenge  $G_2$  (oder in Abb. 5.3.10 II, III bzw. in Abb. 5.3.11 II Binärbild des Laubblattes)
- Gelb: momentanes Bearbeitungselement  $W_3$
- Rot: Einbuchtungsflächen  $G_6$  der zu schneidenden oder geschnittenen Objekte (in Abb. 5.3.10 III Ausschnittskasten)
- Weiß: Skelett  $\Omega_{V_s}(V_j)$ , der zur Bestimmung der Trennlinien gewählten Teilflächen
- Blau: Linienausrichtungspunkte (dreieckig vergrößert:  $W_9$ , viereckig vergrößert:  $W_{10}$ )
- Violett: Schnitt- bzw. Trennlinie  $W_{13}$

Abbildung 5.3.9 zeigt die Blattanzahlbestimmung an einem Laubblatt einer Flügelnuß (*Pterocarya fraxinifolia*). Teilbild I gibt den Zustand wieder, nachdem 4 Objekte durch geringe bzw. mittlere Erosionen in die Ergebnismenge überführt wurden. Das Bearbeitungsobjekt (gelb) konnte durch einige Erosionsschritte vom Hauptblatt abgetrennt werden. Es kann aber aufgrund seiner geringen Konvexität nicht durch Erosionen in mehrere Objekte überführt werden, da ansonsten die Erosionsgrenze überschritten würde. Teilbild II zeigt den stattdessen durchgeführten ersten Trennungsschnitt, der das unterste Teilobjekt abtrennt und in die Ergebnismenge überführt. Der gelbe obere Teil verbleibt in der Bearbeitungsmenge. Teilbild III gibt den Zustand des Algorithmus nach mehreren Schnitten und Erosionen wieder. Teilbild IV zeigt das Endergebnis, bei dem 3 Blättchen durch leichte Erosion, 1 Blättchen durch mittlere Erosion, 2 Blättchen durch starke Erosion und 12 Blättchen mit Hilfe des Schnittverfahrens getrennt und in Objekte, die das Konvexitätskriterium erfüllen, überführt wurden.

Abbildung 5.3.10 hebt die Vorgehensweise der Trennlinienbestimmung noch einmal hervor. Die Zahlen geben die Reihenfolge der Trennschnitte an. Es wird deutlich, daß zuerst

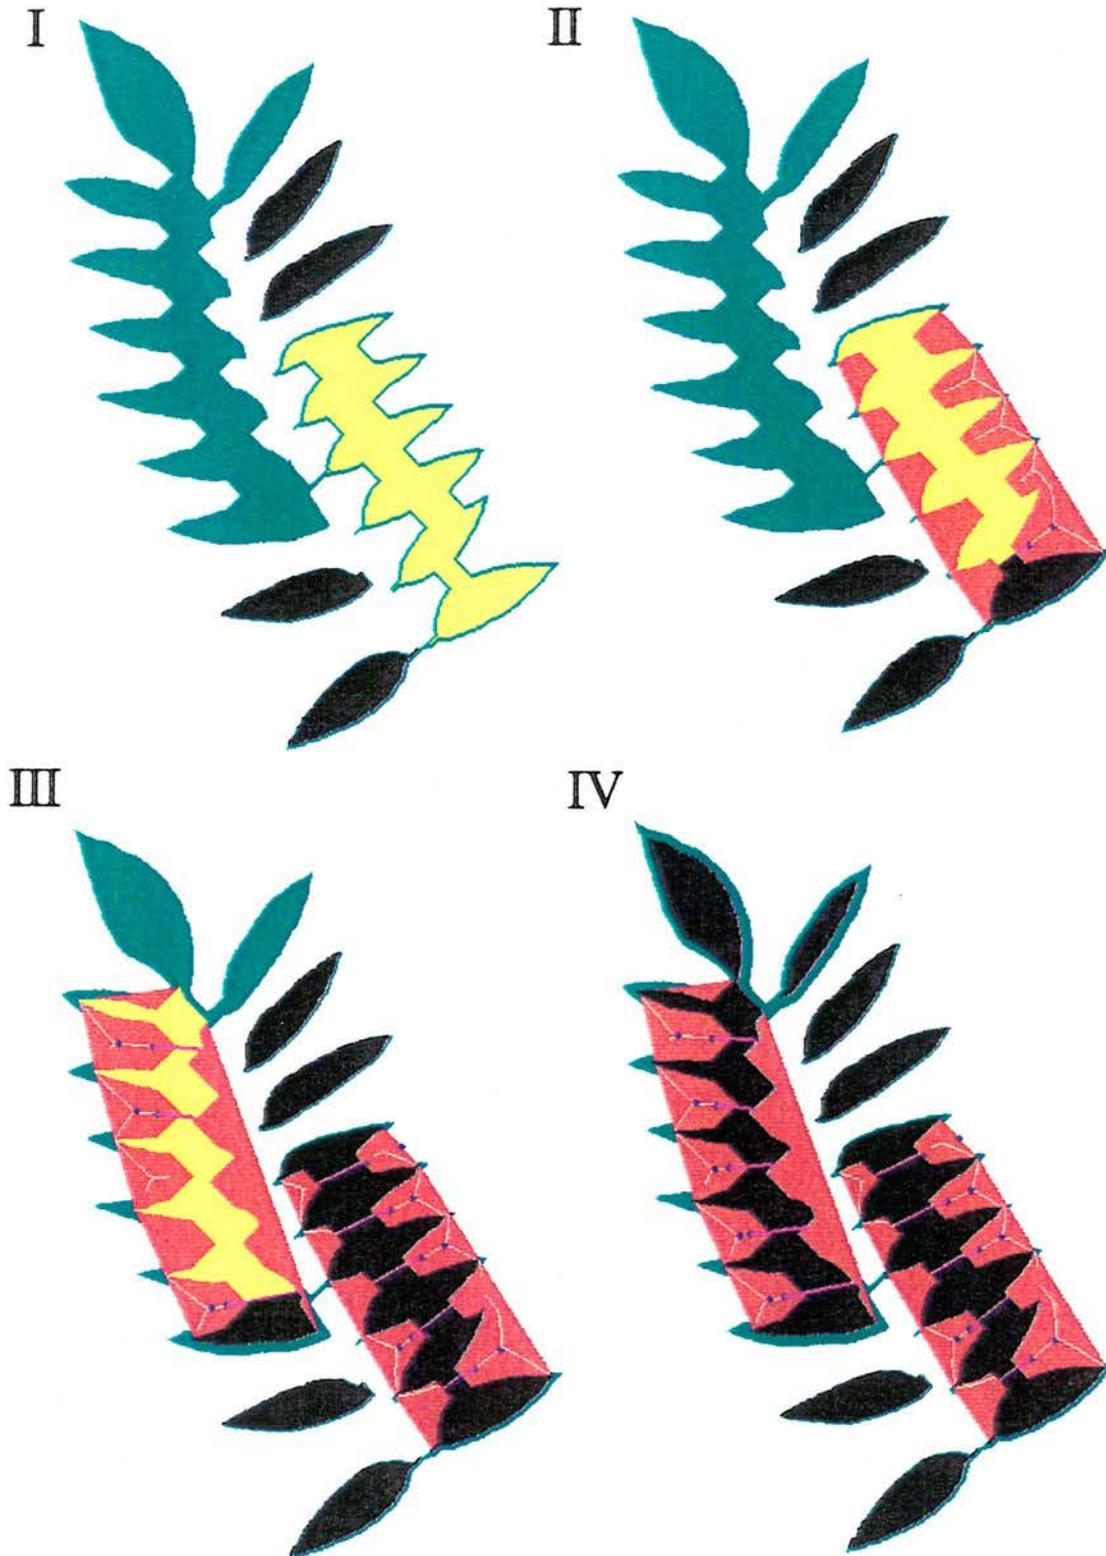


Abb. 5.3.9: Berechnung der Blättchenanzahl am Beispiel eines zusammengesetzten Blattes einer Flügelnuß (*Pterocarya fraxinifolia*)

„sichere“ Schnitte ausgeführt werden. Je länger die Blätter manipuliert werden, desto geringere Einbuchtungen müssen verwendet werden, um die Trennschnitte anzubringen. Trennschnitte 1 bis 4 sind Beispiele für die Linienentwicklung mit Skelettkreuzungspunkten (vgl. 5.4). Trennschnitt 5 wurde nach dem Verfahren ohne Kreuzungspunkt entwickelt (vgl. 5.5)

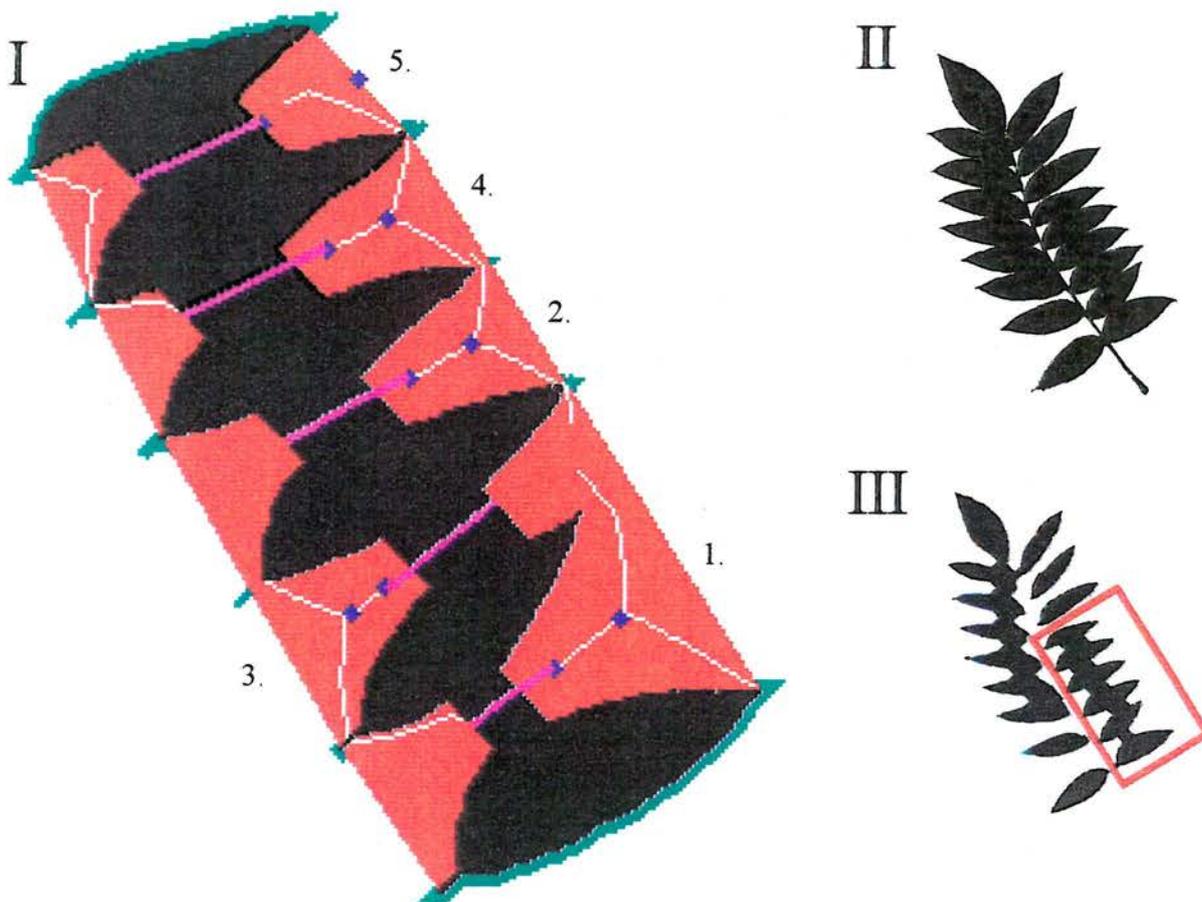


Abb. 5.3.10: Ausgangsbilder und detaillierte Darstellung der Schnittlinienbestimmung aus Abbildung 5.3.9

Abbildung 5.3.11 zeigt die Wirkungsweise des Algorithmus an einem stark überlappenden Blatt einer Roßkastanie (*Aesculus hippocastanum*) (Teilbild I: Endergebnis, Teilbild II: un bearbeitetes Binärbild). Man erkennt, daß bereits die zur Stieleliminierung notwendigen Erosionen einen deutlichen Beitrag zur Trennung der Einzelobjekte liefern. Trotzdem ist es

aufgrund der breiten Überlappungsfronten auch hier nicht möglich, allein durch Erosion eine vollständige Objekttrennung durchzuführen (durch starke Erosionen würde z.B. das kleine Blättchen links in Teilbild I nicht abgetrennt, sondern entfernt). Durch die vorgegebene Erosionsobergrenze von 0,75 ergeben sich stattdessen die drei dargestellten Trennlinien zur Objektvereinzelung.

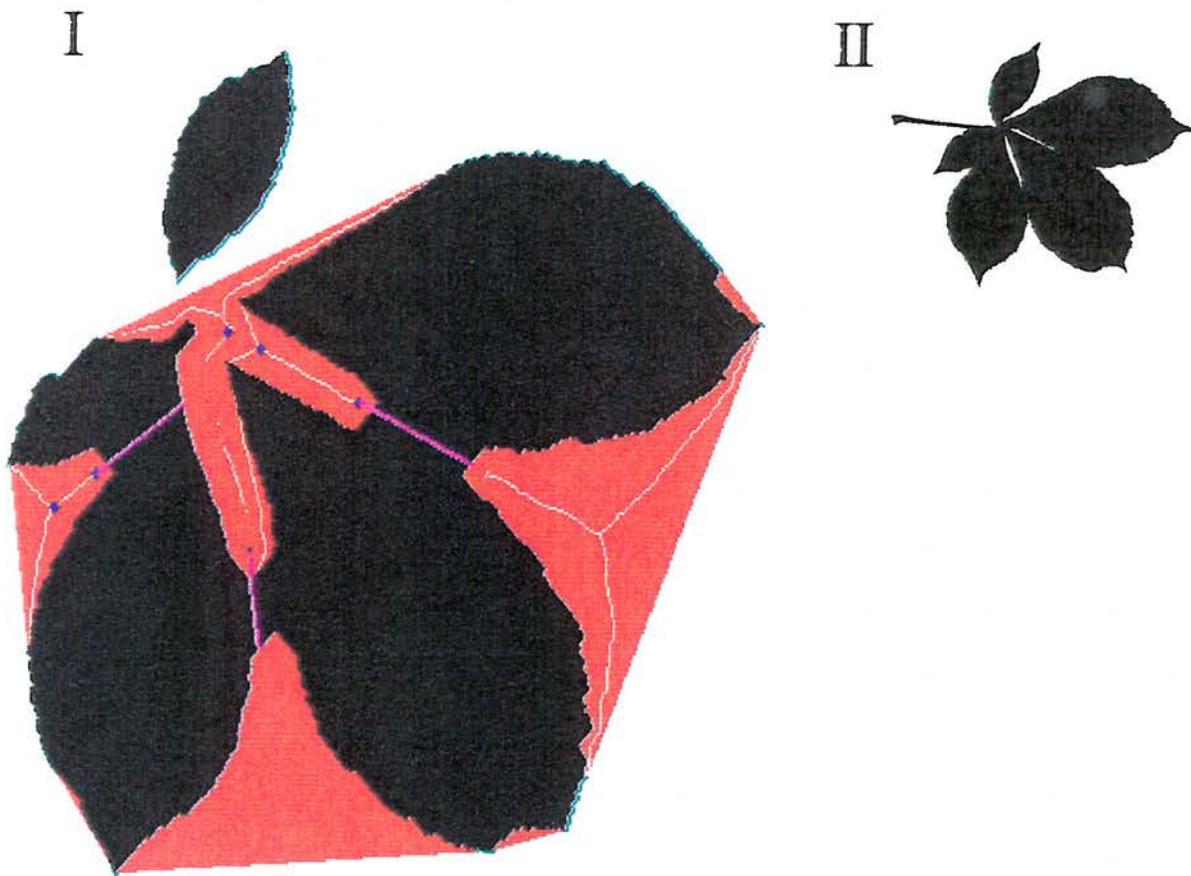


Abb. 5.3.11: Berechnung der Blättchenanzahl am Beispiel eines stark überlappenden Blattes einer Roßkastanie (*Aesculus hippocastanum*)

### 5.3.6 Erkennung und Auswertung der Blattlappen

Wie aus Kapitel 3 und Kapitel 5.2 deutlich wird, ist die Bestimmung der Anzahl der Blattlappen bei einigen Arten ein wichtiges Unterscheidungsmerkmal. Aufgrund der Tatsache, daß der Übergang zwischen eingebuchteten oder eingeschnittenen und gelappten Blättern fließend ist und je nach Bestimmungsschlüssel Blattlappen unterschiedlich interpretiert werden, mußte ein spezielles Verfahren zur Definition und Bestimmung der Blattlappigkeit erstellt werden.

In einem ersten Schritt wird aus der Blattspreite mit Hilfe der konvexen Hülle die größte Einbuchtung extrahiert und vermessen. Anschließend wird die konvexe Hülle bis zu einer bestimmten Tiefe (25 %) der größten Einbuchtung erodiert, um Feineinbuchtungen, die blattrandbedingt sind, zu eliminieren. Die übriggebliebenen Einbuchtungen werden getrennt, eventuell noch um Störungen reduziert und ergeben - um 1 erhöht - die Anzahl der Blattlappen. Diese Anzahl muß nicht zwingend mit der angegebenen Lappenanzahl innerhalb der Bestimmungsschlüssel übereinstimmen; sie stellt vielmehr einen objektiven, nach festen Kriterien bestimmten Blattparameter dar.

Um bei einfachen Blättern nicht fälschlicherweise Blatzzählungen als zahlreiche Blattlappen zu interpretieren, wurde das beschriebene Verfahren nur bei einfachen Blättern mit geringer Konvexität (Schwelle 0,83, vgl. hierzu Abb. 6.1.3) durchgeführt. Ebenso erfolgte keine Anwendung des Verfahrens bei zusammengesetzten Blättern, da es sich nicht um Blattlappen, sondern um Einzelblätter handelt. In beiden Fällen wurde ein Blattlappenwert von 1 fest vorgegeben.

Der Algorithmus zur Bestimmung der Blattlappenanzahl, einschließlich der in Vorversuchen festgelegten Konstanten, definiert sich wie folgt:

Spezielle Bezeichner:

$W_1$ : skalierte Blattspreite (Blatt ohne Stiel)

$W_2$ : konvexe Hülle der Blattspreite

$W_3$ : Einbuchtungsflächen

$W_4$ : größte Einbuchtungsfläche

- $W_5$ : Äußere Kante der größten Einbuchtungsfläche  
 $W_6$ : erodierte konvexe Hülle  
 $W_7$ : Einbuchtungsflächen nach Erosion  
 $W_8$ : vollständiges Blatt (skaliert)  
 $G$ : getrennte Einbuchtungsflächen (ohne Störungen)  
 $n$ : Erosionstiefe zur Eliminierung der tiefsten Einbuchtung  
 $m$ : berechnete Erosionstiefe zur Lappendefinition

Konstanten:

- $\lambda_1$ : Konvexitätsgrenze, bis wohin Blattlappigkeit vorliegt = 0,83  
 $\lambda_2$ : Anteil der tiefsten Einbuchtung, wie tief erodiert werden soll = 0,25  
 $\lambda_3$ : Störungsanteil = 1000

Berechnungsschritte:

❶ Bildung der konvexen Hülle und Test, ob ein zusammengesetztes Blatt oder ein einfaches Blatt mit hoher Konvexität vorliegt:

$$W_2 := \Phi_H(W_1)$$

Falls  $\varphi_2 = 1$  (zusammengesetztes Blatt) oder  
falls  $\Gamma_H(W_1) > \lambda_1$ , dann  $G := \{ \}$  und weiter bei ❷.

❷ Suche der größten Einbuchtung und des entsprechenden Randabschnittes:

$$W_3 := W_2 \setminus W_1$$

$$W_4 \in \Omega_T(W_3) \quad \text{mit} \quad \Gamma_P(W_4) = \max\left(\left\{\Gamma_P(H) \mid H \in \Omega_T(W_3)\right\}\right)$$

$$W_5 := \Omega_{V_r}(W_2) \cap W_4$$

❸ Berechnung der Einbuchtungstiefe des größten Einbuchtung und der Erosionstiefe  $m$ :

$$m := \lambda_2 n \quad \text{mit} \quad W_4 \setminus \overbrace{\Omega_D^4(W_5)}^n \neq \{ \}, \quad W_4 \setminus \overbrace{\Omega_D^4(W_5)}^{n+1} = \{ \}$$

④ Erosion der konvexen Hülle, Einbuchtungsflächen separieren, Störungen eliminieren:

$$W_6 := \overbrace{\Omega_E^4(W_2)}^m, \quad W_7 := W_6 \setminus W_1$$

$$\mathbf{G} := \left\{ H \mid H \in \Omega_T(W_7), \Gamma_P(H) \geq \frac{\Gamma_P(W_8)}{\lambda_3} \right\}$$

⑤. Blattparameter berechnen:

$$\varphi_4 := \Gamma_T(\mathbf{G}) + 1 \quad [-]$$

Abbildung 5.3.12 stellt den entwickelten Algorithmus an zwei Beispielen der Gattung *Quercus* dar. Die grüne plus violett gefärbte Fläche ist die größte Einbuchtung. Die schwarze Linie und der schwarze Punkt sind die Meßpunkte zur Bestimmung der Lappentiefe. Die roten Flächen plus die violett gefärbte Fläche repräsentieren nach der Erosion die Lappenanzahl (in Teilbild I sind es  $8 + 1 = 9$  Lappen, in Teilbild II sind es  $5 + 1 = 6$  Lappen).

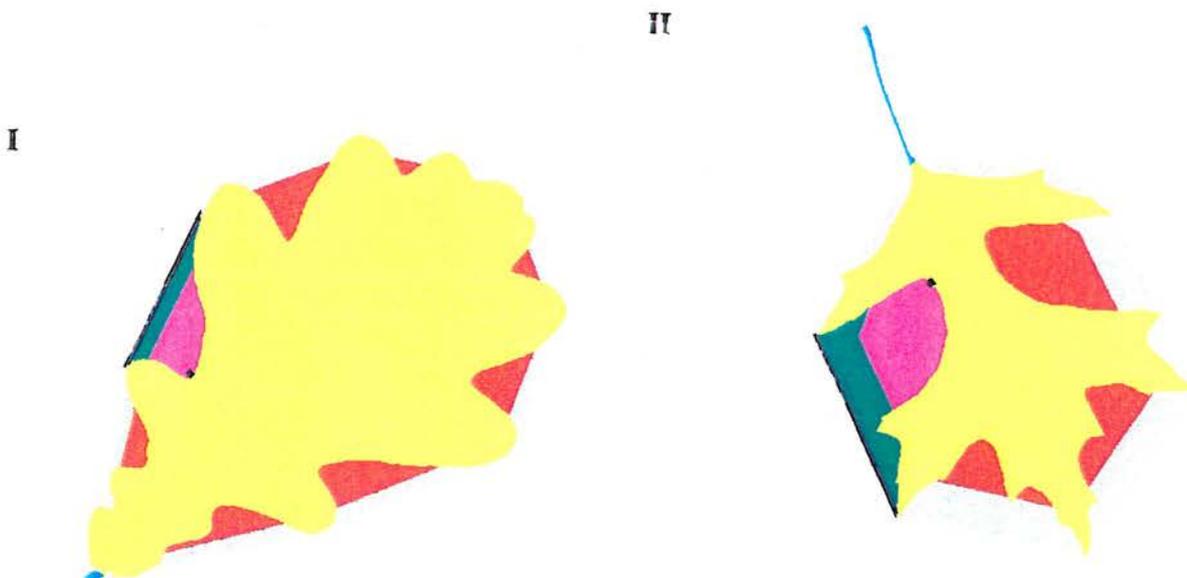


Abb. 5.3.12: Blattlappenbestimmung am Beispiel von *Quercus palustris* und *Quercus robur*

### 5.3.7 Erkennung und Auswertung des Blattrandes

Zur Merkmalsbestimmung von Blattrandeigenschaften wurden kettencodeähnliche Codierungen des Blattrandes verwendet. Es wurden zwei spezielle Ansätze entwickelt, die jeweils als Abbildungen auf einer Kontur verstanden werden können. Ausgang ist der im folgenden als Richtungscode bezeichnete Code, der wie folgt definiert ist:

$$\diamond_R(t_1, t_2, t_3, \dots, t_n) = (p_2, p_3, \dots, p_n) \quad \text{mit} \quad (5.3.2)$$

$$p_i = \begin{cases} x_i - x_{i-1} & \text{falls } |x_i - x_{i-1}| \leq 4 \\ x_i - x_{i-1} - 8 & \text{falls } |x_i - x_{i-1}| > 4 \text{ und } x_{i-1} < x_i \\ x_i - x_{i-1} + 8 & \text{sonst} \end{cases}$$

$(t_1, t_2, t_3, \dots, t_n)$ : Kettencode

$\diamond_R$ : Richtungscode von  $(t_1, t_2, t_3, \dots, t_n)$

Im Gegensatz zum Kettencode wird somit beim Richtungscode die Richtungsveränderung einer Kontur direkt codiert. Die Größe der Veränderung wird mit dem Betrag von  $p_i$  angegeben, die Richtung mit dem Vorzeichen.

Wird der Richtungscode im Hinblick auf Stärke und Häufigkeit der Richtungswechsel analysiert, kann folgender Code definiert werden:

$$\diamond_W((p_1, p_2, p_3, \dots, p_n), \lambda) = (t_1, t_2, t_3, \dots, t_n) \quad \text{mit} \quad (5.3.3)$$

$$t_i = \begin{cases} 1 & \text{falls } \left| \sum_{j=m_i+1}^i p_j \right| \geq \lambda \\ 0 & \text{sonst} \end{cases} \quad \text{mit}$$

$$t_0 = 1 \quad \text{und} \quad m_i = \max\{k \mid t_k = 1, k < i, k \in \mathbb{IN}_0\}$$

$(p_1, p_2, p_3, \dots, p_n)$ : Richtungscode

$\lambda$ : Grenzwert, ab dem der Richtungswechsel registriert wird (2 oder 3)

$\diamond_W$ : Richtungswechselcode von  $(p_1, p_2, p_3, \dots, p_n)$  mit  $\lambda$

Eine Analyse des Richtungswechselcodes hinsichtlich der Codelängen, bis der entsprechende Richtungswechsel vollzogen ist, ergibt einen neuen komprimierten, als Wechsellängencode bezeichneten Code:

$$\diamond_L(t_1, t_2, t_3, \dots, t_n) = (p_1, p_2, p_3, \dots) \quad \text{mit} \quad (5.3.4)$$

$$p_i = \sum_{l=1}^{x_i} t_l - \sum_{j=0}^{i-1} p_j \quad \text{mit}$$

$$x_i = \min(\{k \mid t_k = 1, k > x_{i-1}, k \in \mathbb{IN}_0\}), \quad x_0 = 0 \quad \text{und} \quad p_0 = 0$$

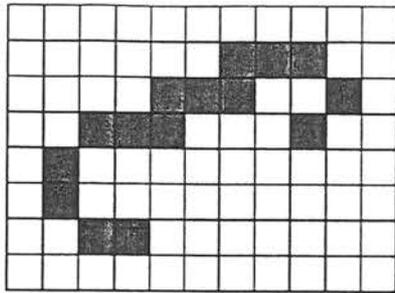
$(t_1, t_2, t_3, \dots, t_n)$ : Richtungswechselcode

$\diamond_L$ : Wechsellängencode von  $(t_1, t_2, t_3, \dots, t_n)$

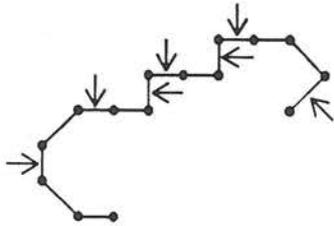
Der Wechsellängencode gibt an, nach wieviel Pixeln jeweils die Richtungsänderung die Stärke  $\lambda$  überschritten hat. Er ist somit ein Maß für die Gleichmäßigkeit der Konturlinie. Es ist zu beachten, daß der Wechsellängencode für gleichlange Kettencodes eine unterschiedliche Anzahl an Elementen beinhalten kann. Eine Verdeutlichung der entwickelten Codierungen zeigt Abb. 5.3.13 an einem einfachen Konturbeispiel.

Aufbauend auf den beschriebenen Codierungsverfahren werden für jeden Blattrand drei spezifische Parameter berechnet, deren Auswahl in Vorversuchen varianzanalytisch erfolgte. Um die Blattrandeigenschaften maximal zu nutzen, wird im Gegensatz zu den anderen Merkmalsbestimmungen das unskalierte Originalbild eingesetzt. Nach Reduzierung des Blattes um den Blattstiel erfolgt die Auswahl der größten Teilfläche zur weiteren Blattrandanalyse. Entgegen dem Bestimmungsschlüssel von FITSCHEN (1994) werden somit auch bei zusammengesetzten Blättern Blattrandeigenschaften zur Blattidentifikation genutzt. Diese entspricht einem Verfahren, welches GODET (1987) in seiner Bestimmung einsetzt.

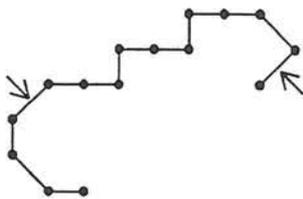
Da Laubblätter zum Teil deutlich unterschiedliche Blattrandausprägungen an ein und demselben Blatt haben, wird zur Randanalyse das Kettencodestück ausgewählt, welches den häufigsten Richtungswechsel (bei  $\lambda = 2$ ) verursacht. Die Länge dieses Teilstückes ergibt sich aus der Gesamtlänge des Kettencodes und einem Längenfaktor, der den Anteil



Ausgangskontur



Richtungswechsel bei  $\lambda = 2$



Richtungswechsel bei  $\lambda = 3$

6	7	0	1	2	2	0	2	2	0	2	2	3	5	Kettencode
	1	1	1	1	0	-2	2	0	-2	2	0	1	2	Richtungscode
	0	1	0	1	0	1	1	0	1	1	0	0	1	Richtungswechselcode ( $\lambda = 2$ )
		2		2		2	1		2	1			3	Wechsellängencode ( $\lambda = 2$ )
	0	0	1	0	0	0	0	0	0	0	0	0	1	Richtungswechselcode ( $\lambda = 3$ )
			3										10	Wechsellängencode ( $\lambda = 3$ )

Abbildung 5.3.13: Beispiele für die entwickelten Kettencodierungsansätze

wiedergibt. Der Längenfaktor wurde aufgrund von Vorversuchen auf 0,25 festgelegt. Die drei Blattrandparameter ergeben sich aus der auf 1000 Pixel normierten Summe des Richtungswechselcodes für  $\lambda = 2$  (entspricht  $90^\circ$ ) und  $\lambda = 3$  (entspricht  $135^\circ$ ), sowie aus der Varianz innerhalb des Wechsellängencodes. Der Algorithmus definiert sich wie folgt:

Spezielle Bezeichner:

$W_1$ : Originalblatt (unskaliert), (Punktmenge)

$W_2$ : Blatt- und Blättchenstiele des unskalierten Originalblattes, (vgl. Kap. 5.3.2)

$W_3$ : zu analysierende Blattfläche

$m_1$ : Anzahl Elemente des Ausgangskettencodes

$m_2$ : Anzahl Elemente des zu analysierenden Teilstückes des Kettencodes

$m_3$ : Anzahl Elemente im Wechsellängencode

$T_1$ : Kettencode der zu analysierenden Blattfläche

$T_2$ : verlängerter Kettencode

$T_3$ : Richtungscode

$T_4$ : zu analysierender Richtungscode (Ausschnitt)

Konstanten (in Vorversuchen bestimmt):

$\lambda_1$ : Schwellenwert für Erfassung des Richtungswechsels = 2

$\lambda_2$ : Schwellenwert für Erfassung des Richtungswechsels = 3

$\lambda_3$ : Längenfaktor = 0,25

Berechnungsschritte:

❶ Stiele vom Blatt entfernen, größte Restfläche suchen:

$$W_3 := H \quad \text{mit} \quad \Gamma_P(H) = \max\left(\left\{\Gamma_P(V) \mid V \in \Omega_T(W_1 \setminus W_2)\right\}\right)$$

❷ Kettencode und Längen des Kettencodes und des zu analysierenden Teilcodes bestimmen:

$$T_1 := \diamond_K(\Omega_{V_r}(W_3))$$

$$m_1 := n \quad \text{mit} \quad (t_1, t_2, t_3, \dots, t_n) = T_1$$

$$m_2 := \max\left(\left\{k \mid k \leq \lambda_3 m_1, k \in \mathbb{IN}_0\right\}\right)$$

❸ Kettencode verlängern, Richtungscode erzeugen:

$$T_2 := (t_1 \dots t_{m_1}, t_1 \dots t_{m_2}) \quad \text{mit} \quad (t_1, t_2, t_3 \dots) = T_1$$

$$\mathbb{T}_3 := \diamond_R(\mathbb{T}_2)$$

- ④ Abschnitt des Blattrandes bestimmen, der zur Analyse verwendet werden soll:

$$\mathbb{T}_4 := (t_1, t_2, t_3, \dots, t_{m_2}) \quad \text{mit}$$

$$t_i = p_{i+z-1} \quad \text{mit} \quad (p_1, p_2, p_3 \dots) = \mathbb{T}_3 \quad \text{und} \quad \sum_{n=z}^{z+m_2-1} p_n = \max_{j=1 \dots m_1} \left( \sum_{k=j}^{j+m_2-1} p_k \right)$$

- ⑤ Auf 1000 Pixel normierte Richtungswechsel mit  $\lambda_1$  (90 °) und  $\lambda_2$  (135 °) bestimmen:

$$\varphi_{12} := \frac{1000}{m_2} \sum_{k=1}^{m_2} t_k \quad [-] \quad \text{mit} \quad (t_1, t_2, t_3, \dots, t_{m_2}) = \diamond_W(\mathbb{T}_4, \lambda_1)$$

$$\varphi_{13} := \frac{1000}{m_2} \sum_{k=1}^{m_2} t_k \quad [-] \quad \text{mit} \quad (t_1, t_2, t_3, \dots, t_{m_2}) = \diamond_W(\mathbb{T}_4, \lambda_2)$$

- ⑥ Varianz der Richtungswechsel (mit  $\lambda_1$ ) bestimmen:

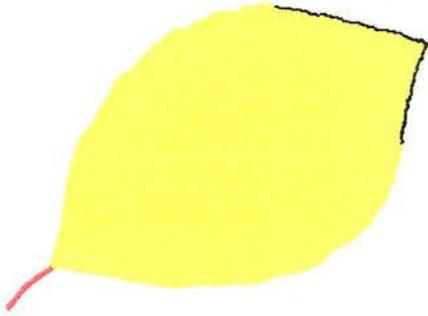
$$\varphi_{14} := \begin{cases} \frac{1}{m_3 - 1} \sum_{k=1}^{m_3} \left( t_k - \frac{1}{m_3} \sum_{j=1}^{m_3} t_j \right)^2 & \text{falls } m_3 > 4 \\ \text{nicht definiert (1000)} & \text{sonst} \end{cases} \quad [-] \quad \text{mit}$$

$$(t_1, t_2, t_3, \dots, t_{m_3}) = \diamond_L(\diamond_W(\mathbb{T}_4, \lambda_1))$$

Abbildung 5.3.14 stellt den beschriebenen Algorithmus am Beispiel mehrerer Blätter dar. Die gelben Flächen sind die ausgewählten Analyseflächen. Die schwarze Kontur gibt den ausgewählten Konturbereich an und die Zahlen stellen die ermittelten Parameter in der Reihenfolge  $\varphi_{12}$ ,  $\varphi_{14}$ ,  $\varphi_{13}$  dar. Bei nicht definierter Variable  $\varphi_{14}$  wurde standardmäßig der Wert 1000 gesetzt. In der Abbildung sind diese Fälle mit 'nicht def.' gekennzeichnet.

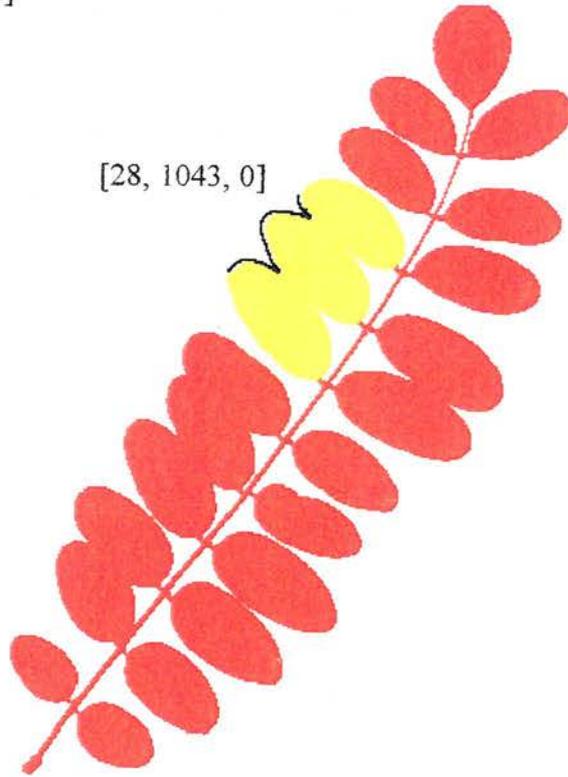
*Fagus sylvatica*

[3, nicht def., 3]



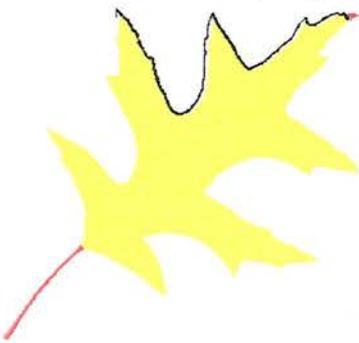
*Robinia pseudoacacia*

[28, 1043, 0]



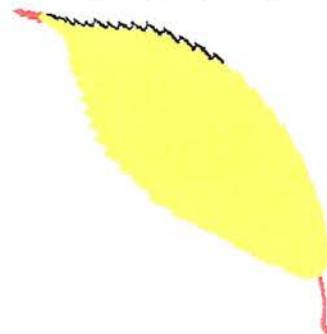
*Quercus coccinea*

[45, 792, 11]



*Acer carpinifolium*

[205, 11, 104]



*Betula pubescens*

[135, 37, 76]

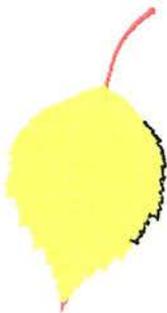


Abbildung 5.3.14: Blattrandcodierungen an verschiedenen Beispielen (Erklärung im Text)

## 5.4 Entwickelte Bestimmungsmodelle

### 5.4.1 Allgemeines zur Datenaufbereitung und -verwendung

Zur Bildung der Auswertemodelle müssen die erzeugten Datensätze in Zielgruppen eingeteilt werden. Es bietet sich an, für jede Art eine Unterscheidungsgruppe zu bilden. Prinzipiell können auch mehrere Gruppen eine Art repräsentieren, was dann bei der Identifikation mehrere Bestimmungswege darstellen würde. Im vorliegenden Fall wurde jede Art grundsätzlich in einer Gruppe zusammengefaßt. Ausnahme bildete die Art *Aesculus hippocastanum*. Sie konnte aufgrund ihres gefingerten Spreitenaufbaus nicht eindeutig der Klasse der einfachen oder der zusammengesetzten Blättern zugeordnet werden. Da aber gerade die Bestimmung des Blattaufbaus (einfach oder zusammengesetzt) nicht nur als Blattmerkmal, sondern auch zur Auswahl der zur weiteren Merkmalextraktion notwendigen Algorithmen wichtig war, wurde *Aesculus hippocastanum* mit zwei verschiedenen Gruppen (jeweils 10 Aufnahmen mit entsprechender Variable  $\varphi_2$ ) repräsentiert. Eine computergestützte Zuordnung eines einfachen *Aesculus*-Blattes in die Gruppe der zusammengesetzten *Aesculus*-blätter (oder umgekehrt) wurde bei der späteren Klassifikationsberechnung mit einer Oder-Verknüpfung überprüft (es sei hier vorweggenommen, daß dieser Fall aufgrund der deutlichen Parameterunterschiede in keinem Fall zutraf). Insgesamt standen somit 52 Gruppen (51Arten) zur Bildung von Klassifikationsmodellen zur Verfügung.

Für jedes Blatt wurden die 21 Blattmerkmale bestimmt. Sie ergaben den das Blatt charakterisierenden Datenvektor. Die Entwicklung der Auswerte- bzw. Klassifikationsmodelle erfolgte mit einem Teil der Daten, der im folgenden als Lerndaten bezeichnet wird. Der anderer Teil wurde zur Überprüfung der Modelle eingesetzt (Testdaten). Benötigten die Modellansätze als Eingabegrößen normierte Vektoren (vgl. Kap. 4.5), wurden alle Datensätze vor der Modellbildung anhand der Spannweiten der einzelnen Variablen innerhalb der Lerndaten linear auf Werte zwischen 0 und 1 normiert (vgl. BOCK 1974). Es gilt:

$$\varphi'_{ij} = \begin{cases} 1 & \text{falls } x_{ij} > \max_k(\varphi_{ik}) \\ 0 & \text{falls } x_{ij} < \min_k(\varphi_{ik}) \\ x_{ij} & \text{sonst} \end{cases} \quad \text{mit} \quad (5.4.1)$$

$$x_{ij} = \frac{\varphi_{ij} - \min_k(\varphi_{ik})}{\max_k(\varphi_{ik}) - \min_k(\varphi_{ik})}$$

$\varphi_{ij}$ : i-te Komponente des j-ten Datenvektors

$\varphi'_{ij}$ : Auf einen Wert zwischen 0 und 1 normierte i-te Komponente des j-ten Datenvektors

$k$ : Index eines Lerndatenvektors

$j$ : Index eines Lern- oder Testdatenvektors

Die Bildung der Klassifikationsmodelle wird von der Anzahl und der Auswahl der Lerndatensätze beeinflusst. Um Aussagen über die Einsatzfähigkeit eines bestimmten Modellansatzes treffen zu können, muß die Modellbildung mit unterschiedlichen Ausgangsdaten durchgeführt und getestet werden. Aus den vorhandenen Datensätzen wurden deshalb jeweils acht Datensatzvarianten mit Hilfe eines Zufallsgenerators extrahiert. Um unterschiedliche Blatt-aufnahmen zu berücksichtigen, wurde die Extraktion zehn mal wiederholt. Jede Datensatzvariante erfüllte folgende 3 Kriterien:

1. Eine Datensatzvariante bestand aus einem Lerndatensatz und einem Testdatensatz und beinhaltete 10 Merkmalvektoren aus jeder Unterscheidungsgruppe (d.h. 520 Datenvektoren), wobei die 10 Merkmalvektoren einer Gruppe von 9 verschiedenen Blättern (ein Blatt doppelt mit anderer Auflagerichtung) waren.
2. Die Anzahl der Datensätze jeder Gruppe innerhalb des Lerndatensatzes (und somit auch des Testdatensatzes) war gleich.
3. Die aus den unterschiedlichen Aufnahmerichtungen resultierenden Merkmalvektoren ei-  
nes Blattes befanden sich entweder im Lerndatensatz oder im Testdatensatz, aber nicht in beiden. Das bedeutete, daß ein Blatt des Testdatensatzes niemals zur Modellbildung verwendet wurde (außer bei wissensbasierter Auswertung).

Für die Wiederholungen galt: Eine Wiederholung bestand aus 8 Datensatzvarianten, die sich jeweils in der Anzahl der Blätter innerhalb der Testdatensätze bzw. der Lerndatensätze unterschieden (1 bis 8 Testblätter jeder Gruppe, 2-9 Lernblätter jeder Gruppe).

Insgesamt standen somit 80 mehr oder weniger unterschiedliche Versuchsvarianten zur Bildung der Identifikationsmodelle zur Verfügung.

#### **5.4.2 Modellansatz auf der Basis zweiwertiger Produktionsregelsysteme**

Aufbauend auf dem botanischen Bestimmungsschlüssel von FITSCHEN (1994) wurde ein zweiwertiger Entscheidungsbaum entwickelt. Hierzu wurden die Blattmerkmale ausgesucht, die innerhalb des Schlüssels das Vorliegen einer Art absichern oder ausschließen und die gleichzeitig computerbildanalytisch dargestellt werden können. Im einzelnen war dies: die Blattstellung am Zweig, der Aufbau des Blattes, die Anzahl der Einzelblättchen, das Verhältnis der Länge zur Breite der Blattspreite, die Größe der Blattspreite, die Blattstiellänge und die Zähnung des Spreitenrandes. Zusätzliche Formeigenschaften der Spreite wurden innerhalb des Merkmals Blattaufbau (Gelapptheit) erfaßt. Zur Modellbildung wurde keine Unterscheidung in Lern- und Testdatensätze gemacht.

Die nicht numerischen Merkmale des Bestimmungsschlüssels wurden in Kategorien eingeteilt, die mit fest definierten und in Tab. 5.4.1 dargestellten Parametergrenzen repräsentiert wurden. Die Eingruppierung der Arten in die jeweiligen Kategorien erfolgte anhand der Angaben im Bestimmungsschlüssel, wobei auch die unterschiedliche Bestimmungswege zu einer Art berücksichtigt wurden. Die Parametergrenzen wurden mit Hilfe der vorhandenen Datensätze bestimmt. Lagen offensichtliche Fehlberechnungen der Parameter vor, wurden die entsprechenden Werte zur Regelbildung nicht berücksichtigt. Im Gegensatz zu den anderen Modellansätzen wurde das gesamte verfügbare Wissen, d.h. alle Datensätze zur Modellbildung eingesetzt.

Die numerischen Merkmalsangaben wurden direkt in Regeln umgesetzt. Um auch unscharfe Angaben wie 'ca.' oder 'gewöhnlich' darzustellen und um der etwaigen fehlerhaften computerbildanalytischen Merkmalsgewinnung Rechnung zu tragen, wurden die Angaben jedoch mit unterschiedlichen Auf- bzw. Abschlägen variiert. Bei der Angabe der Anzahl der Einzelblättchen wurde bei einer im FITSCHEN (1994) beschriebenen Blättchenzahl von weniger als 15 eine Toleranz von  $\pm 1$  zugelassen. Bei einer Blättchenanzahl von weniger als 25 betrug die Toleranz  $\pm 3$ , ansonsten  $\pm 4$ . Bei der Angabe der Blattlänge zur Blattbreite

wurden Toleranzen von 0,2 verwendet. Bei Stiellängenangaben wurden die Werte mit einem Auf- bzw. Abschlag von 0,3 cm bis 0,5 cm versehen. Tab. 5.4.1 stellt die verwendeten Merkmale und deren Parametrisierung innerhalb des Regelsystems dar.

Aus den aufgeführten Parametern wurde ein Entscheidungsregelbaum gebildet, der eine möglichst weite Bestimmung einer vorliegenden Art ermöglicht. Da es sich bei den verfügbaren Merkmalen nicht um definitive Merkmale einer bestimmten Art, sondern meistens um ausgrenzende Klassenkriterien handelt, wurden die Regeln nur mit ausschließenden Bedingungen formuliert. Zum Beispiel gibt FITSCHEN (1994) für *Aesculus hippocastanum* eine Blättchenanzahl von „ca. 5“ an. Dieses ergab folgende Regel:

Wenn für das vorliegende Bild  $3 < \varphi_3 < 7$  nicht zutrifft,  
dann handelt es sich nicht um *Aesculus hippocastanum*.

Als weiteres Beispiel ergibt sich aus Tabelle 5.4.1 und der Ganzrandigkeit von *Carpinus betulus* die Bildung folgender Regel:

Wenn für das vorliegende Bild  $\varphi_{12} < 100$  oder  $\varphi_{14} < 50$  nicht zutrifft,  
dann handelt es sich nicht um *Carpinus betulus*.

Insgesamt wurden 176 Regel - wie in den Beispielen beschrieben - erstellt. In der Tabelle 5.4.1 ist in der letzten Spalte jeweils dargestellt, welches Merkmal bzw. welche Kategorie mit wievielen Regeln innerhalb des Entscheidungsbaumes vertreten ist. Neben der offensichtlich sehr unterschiedlichen Häufigkeit bestimmter Bedingungen tauchen auch die einzelnen Schlußfolgerungen innerhalb der Regeln in unterschiedlicher Anzahl auf (je nachdem, wie stark die ausgesuchten Kriterien innerhalb des botanischen Bestimmungsschlüssels Verwendung finden). So wurden einzelne Arten nur mit 1 oder 2 Regeln eingegrenzt, während andere bis zu achtmal in den Regelschlußfolgerungen vertreten waren.

Sollte mit Hilfe des entwickelten Entscheidungsmodells ein Blatt identifiziert werden, wurden zuerst alle 51 Arten als potentielle Lösungen registriert. Anschließend erfolgte die Eingrenzung der möglichen Art durch Abarbeitung aller Regeln. Die Arten, die am Ende dieses Prozesses übrig blieben, ergaben die Lösung des Identifikationsproblems.

Tab. 5.4.1: Merkmalauswahl und Parametrisierung der Entscheidungsregeln

Merkmal	Kategorie	Parametrisierung	Anz*
Blattstellung	wechselständig	$\varphi_1 = 0$	37
	gegenständig	$\varphi_1 = 1$	10
Blattart, Blattaufbau	einfach	$\varphi_2 = 0$	10
	nicht gelappt	$\varphi_7 > 0.83$	16
	gelappt	$\varphi_7 < 0.94$	15
	zusammengesetzt	$\varphi_2 = 1$	11
Blattrandfeinstruktur	ganzrandig	$\varphi_{12} < 100$ und $\varphi_{13} < 50$	6
	gezähnt, gesägt, gekerbt	$\varphi_{12} > 50$	9
	scharf gezähnt, gezähnt, gekerbt	$\varphi_{12} > 100$ und $\varphi_{13} > 0$	9
	regelm. oder doppelt ge- zähnt, gesägt, gekerbt	$\varphi_{14} < 100$	3
Blattgröße	klein	$\varphi_5 < 100000$	4
	nicht klein	$\varphi_5 > 100000$	11
	nicht auffällig groß	$\varphi_5 < 300000$	1
	auffällig groß	$\varphi_5 > 300000$	1
Blättchenanzahl	-	$z_1 < \varphi_3 < z_2$	11
Länge zu Breite	-	$z_1 < \varphi_6 < z_2,$ $z_1 < \varphi_6, \quad z_1 > \varphi_6$	6
Blattstiellänge	-	$z_1 < \varphi_{15} < z_2,$ $z_1 < \varphi_{15}, \quad z_1 > \varphi_{15}$	16

$z_i$  = numer. Angaben im Bestimmungsschlüssel, \*Anz = Anzahl der Regeln, die das Merkmal verwenden

### 5.4.3 Fuzzy-Logik-orientierter Modellansatz

Zur Bildung der Klassifikationsmodelle mit Hilfe des Fuzzy-Logik-Ansatzes wurde ein Verfahren entwickelt, bei dem aus den Lerndaten für jedes Pflanzenmerkmal Zugehörigkeitswertfunktionen für jede Art berechnet werden. Zur Identifikation eines unbekanntes Blattes wurden für alle Arten diese Zugehörigkeitsfunktionen ausgewertet und für jede Art mit dem Mittelwertoperator verdichtet. Die Art, die über alle Pflanzenmerkmale den höchsten Mittelwert erzielte, bei der also der Ausdruck

$$\frac{1}{21} \sum_{i=2}^{22} f_{Z \tilde{F}_j}(\varphi_i) \quad (5.4.2)$$

$\varphi_i$ : Blattmerkmal

$f_{Z \tilde{F}_j}$ : Zugehörigkeitsfunktion zur unscharfen Pflanzengruppe(Art)  $\tilde{F}_j$

maximiert wurde, stellte das Identifikationsergebnis  $j$  dar. Durch Ausgabe der nach Höhe sortierten Zugehörigkeitswerte war es auch möglich, eine Erkennungsrangfolge als Ergebnis zu erzeugen.

In herkömmlichen Fuzzy-Systemen werden die Zugehörigkeitsfunktionen aus Erfahrungswerten oder Expertenwissen abgeleitet. In dem hier beschriebenen Klassifikationsfall stand solches Wissen jedoch nicht zur Verfügung, da erstens Bestimmungsschlüssel nicht speziell auf die Darstellung von unscharfen Regeln abgestimmt werden (siehe FITSCHEN 1994) und da zum zweiten die computerbildanalytisch extrahierten Merkmale nur zum Teil exakt mit den botanischen Klassifikationskriterien übereinstimmen oder über die in Klassifikationsschlüsseln beschriebenen Kriterien hinausgehen. Aus diesem Grund wurden jeweils aus den Daten der Lerndatensätze auf den grundlegenden statistischen Kennzahlen (Mittelwert und Standardabweichung) basierende Zugehörigkeitsfunktionen gebildet. Aufbauend auf der normierten Gaussverteilung ergibt sich die Zugehörigkeitsfunktion zu :

$$f_{Z \tilde{F}_j}(\varphi_i) = \begin{cases} 1 & \text{falls } \sigma_{ij} = 0 \\ 1 & \text{falls } x > 1 \\ x & \text{sonst} \end{cases} \quad \text{mit} \quad x = \frac{e^{-0,5 \left( \frac{\varphi_i - \bar{\varphi}_{ij}}{\sigma_{ij}} \right)^2}}{e^{-0,5 z_{ij}^2}} \quad (5.4.3)$$

$f_{Z \tilde{F}_j}$ : Zugehörigkeitsfunktion zur unscharfen Pflanzengruppe  $\tilde{F}_j$

$\sigma_{ij}$ : Standardabweichung des Merkmals  $i$  in der Gruppe  $j$  (Lerndaten)

$\bar{\varphi}_{ij}$ : arithmetisches Mittel des Merkmals  $i$  in der Gruppe  $j$  (Lerndaten)

$\varphi_i$ : Blattmerkmal  $i$  eines Testblattes

$z_{ij}$ : Optimierungswert für Merkmal  $i$  und Gruppe  $j$

Abbildung 5.4.1 stellt schematisch die Bildung der Zugehörigkeitsfunktionen dar. Die Standardabweichungen und Mittelwerte normieren die Daten und stellen zusammen mit den z-Werten die entscheidenden Modellparameter dar. Die z-Werte geben jeweils die Breite

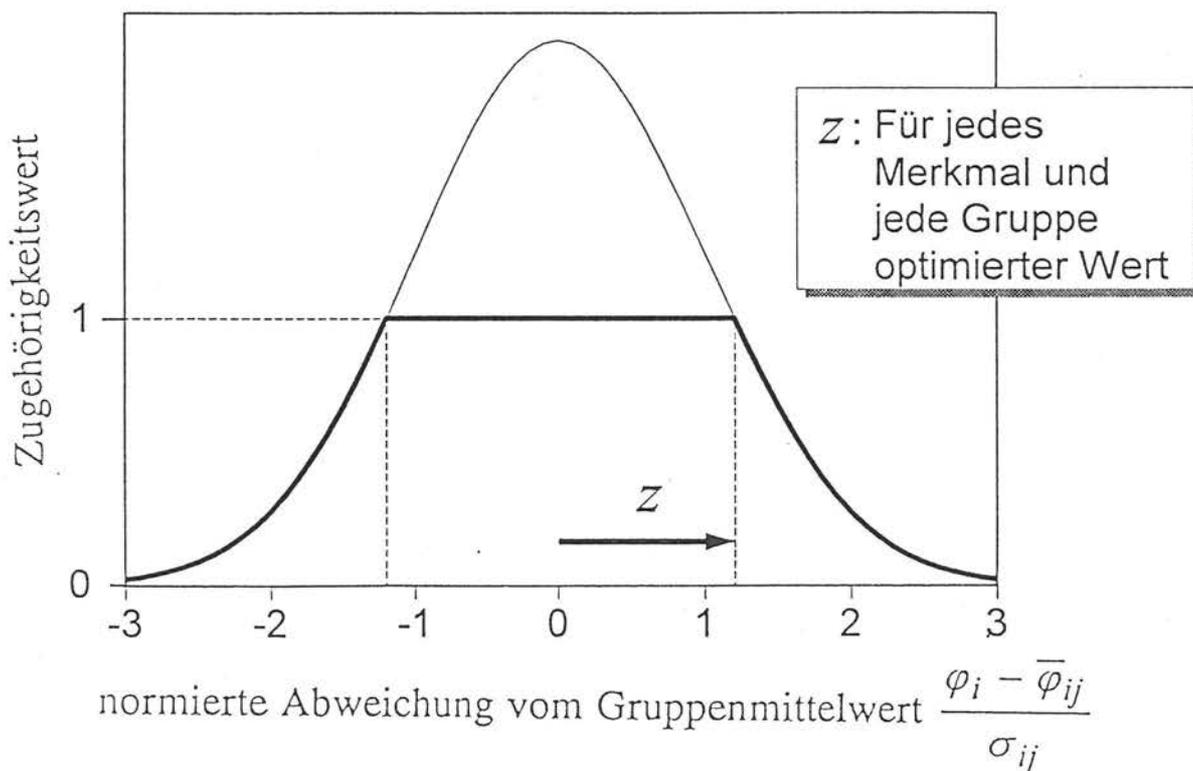


Abbildung 5.4.1: Schematische Darstellung der Bildung der Zugehörigkeitsfunktion

der Zugehörigkeitsfunktionen an. Sie wurden für jede Art und jedes Merkmal so gewählt, daß eine optimale Trennung der Arten erfolgen konnte. Im einzelnen wurde für jede Unterscheidungsgruppe  $j$  und jedes Merkmal  $i$  der Wert

$$\sum_{k=1}^{52} x_{ijk} \quad \text{mit} \quad (5.4.4)$$

$$x_{ijk} = \begin{cases} 0,2 & \text{falls } y_{ij} - y_{ik} > 0,2 \\ y_{ij} - y_{ik} & \text{sonst} \end{cases} \quad \text{mit}$$

$$y_{im} = \frac{1}{l} \sum_{n \in L_m} f_{Z \tilde{F}_m}(\varphi_{in})$$

$\varphi_{in}$ : Merkmal  $i$  des Blattes  $n$

$L_m$ : Indices der Blätter des Lerndatensatzes der Gruppe  $m$

$l$ : Anzahl der Blätter pro Gruppe innerhalb des Lerndatensatzes

$f_{Z \tilde{F}_m}$ : Zugehörigkeitsfunktion zur unscharfen Pflanzengruppe  $m$

$y_{im}$ : durchschnittlicher Zugehörigkeitswert für Merkmal  $i$  zur Gruppe  $m$  (Lerndatensatz)

$x_{ijk}$ : Gruppenabstand zwischen Gruppe  $j$  und Gruppe  $k$  für Merkmal  $i$  (Lerndatensatz)

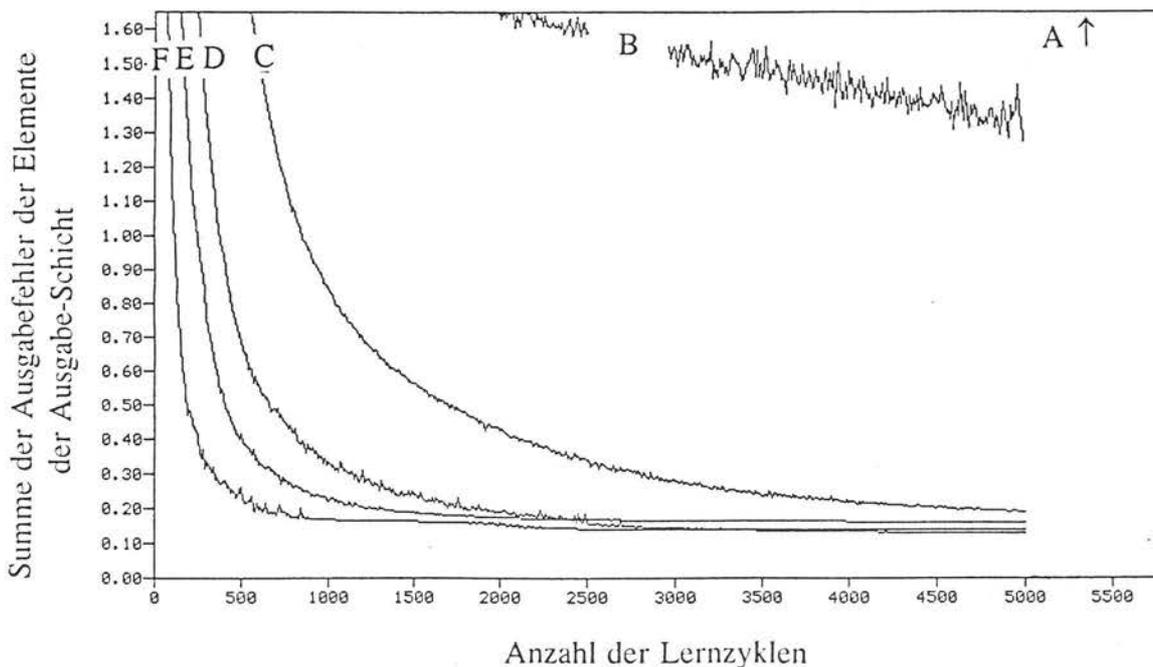
maximiert. Dabei wurden die Berechnungen mit unterschiedlichen  $z$ -Werten, die von 0,1 bis 3,0 in 0,1-Schritten variierten, durchgeführt und am Ende der beste  $z$ -Wert ausgewählt.

#### 5.4.4 Modellansätze auf der Basis neuronaler Netzwerke

Aufgrund von Voruntersuchungen (siehe RATH 1996c) wurde zur Datenauswertung ein 3-schichtiger Backpropagationansatz mit 21 Elementen innerhalb der Eingabeschicht zur Aufnahme des Merkmalvektors ausgewählt. Die Ausgabeschicht bestand aus 52 Elementen, deren Ausgabewerte jeweils die Unterscheidungsgruppen repräsentierten (bei Vorliegen der ersten Unterscheidungsgruppe hatte zum Beispiel das erste Netzelement den Sollwert 1 und alle anderen den Sollwert 0).

Zur Optimierung der Netzzusammenstellung und des Lernverhaltens wurden verschiedene Netzkonfigurationen getestet: Die verdeckte Mittelschicht bestand wahlweise aus 5, 10 oder 100 Elementen. Die Elemente waren zwischen den Schichten vollständig miteinander verknüpft. Als Inputfunktion wurde die Summenfunktion, als Outputfunktion die Identitätsfunktion und als Transferfunktion die sigmoide Logistik-Funktion (siehe RATH 1996c, ZELL et al. 1994) ausgewählt. Als Lernmechanismus wurde wahlweise einfaches Backpropagationlernen (vgl. Formel 4.5.10) oder Backpropagationlernen mit Momentum mit unterschiedlichen Lernraten und Momentumwerten eingesetzt. Die Merkmale wurden vor Verwendung auf Werte zwischen 0 und 1 normiert (Formel 5.4.1).

Die Auswahl der eingesetzten Netze erfolgte anhand der Lernverläufe für Lerndatensätze bestehend aus 5 Blättern pro Gruppe. Abbildung 5.4.2 stellt die Ergebnisse dar. Man erkennt, daß sich das Netz bei 5 Netzelementen innerhalb der verborgenen Mittelschicht trotz intensiver Lernvorgänge nur unzureichend an den Datensatz anpassen konnte.

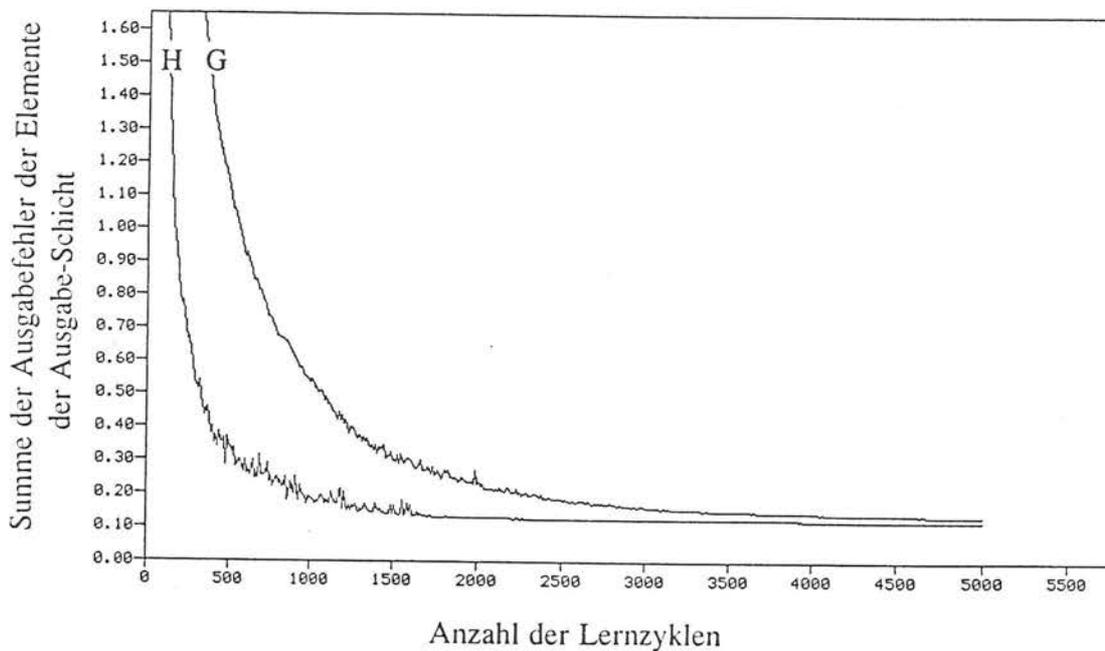


A: 5 Elemente, Lernrate = 0,2    C: 10 Elemente, Lernrate = 0,2    E: 100 Elemente, Lernrate = 0,2  
 B: 5 Elemente, Lernrate = 0,5    D: 10 Elemente, Lernrate = 0,5    F: 100 Elemente, Lernrate = 0,5

Abbildung 5.4.2: Lernverlauf getesteter 3-schichtiger Backpropagation-Netze

Bei 100 Netzelementen wurden keine wesentlich besseren Ergebnisse als mit 10 Elementen erzielt. Hingegen betrug die Trainingszeit für Variante E und F ca. 10 Stunden gegenüber 1,5 Stunden bei C und D.

Abbildung 5.4.3 stellt die Lernverlaufskurven der Netze mit 10 Elementen (innerhalb der Mittelschicht) plus Momentum dar.



G: 10 Elemente; Lernrate = 0,2; Momentum = 0,5    H: 10 Elemente; Lernrate = 0,5; Momentum = 0,5

Abbildung 5.4.3: Lernverlauf von 3-schichtigen Backpropagation-Netzen mit Momentum-term

Es wird deutlich, daß gegenüber den Varianten C und D durch den Einsatz des Momentum-terms eine Beschleunigung und Verbesserung des Lernverhaltens eintritt. Aufgrund der Ergebnisse der beschriebenen Voruntersuchungen wurden folgende Netzvarianten für die weitere Modellbildung ausgewählt: Backpropagation-Netz mit 10 Elementen innerhalb der Mittelschicht und einer Lernrate und einem Momentum von jeweils 0,5. Da unsicher war, ob das im Lernverhalten beste Netz auch die besten Klassifikationsergebnisse in unbekannter Situation erbringt, wurden jeweils Netzvarianten mit 100, 500, 2000 und 5000 Lernzyklen berechnet.

### 5.4.5 Statistische Modellansätze

Es erfolgte eine lineare und eine quadratische Diskriminierung mit unnormierten Datensätzen nach der in Formel 4.5.3 und 4.5.4 beschriebenen Berechnungsvorschrift. Ferner wurden drei parameterfreie -Verfahren unter Verwendung der euklidischen Distanz ausgewählt: eine  $k$ -nearest-neighbor-Klassifikation mit  $k=1$  und eine  $k$ -nearest-neighbor-Klassifikation mit  $k=3$  und eine  $k$ -nearest-neighbor-Klassifikation mit  $k=1$ , bei der die Datensätze der Lerndaten vor der Modellierung auf jeweils einen Mittelwertdatensatz verdichtet wurden. Bei den parameterfreien Modellen wurden normierte (vgl. Formel 5.4.1) Daten eingesetzt.

### 5.5 Eingesetzte Hard- und Software

Die Bildaufnahmen erfolgten mit einem handelsüblichen Flachbettscanner (Hewlett-Packard) mit einer Auflösung von 150 dpi und dem Softwaresystem *HP Scanning Gallery* (Hewlett Packard). Die Bildaufbereitung und Merkmalextraktion wurde mit dem Bildanalyzesystem *HORUS* (ECKSTEIN 1994) unter Verwendung der Programmiersprache *SWI-PROLOG* (WIELEMAKER 1992) unter dem Betriebssystem *Limix* durchgeführt. Durch die Einbindung des Bildanalyzesystems *HORUS* in die Prolog-Umgebung war es möglich, Bildanalyseprozeduren direkt als Prolog-Terme oder in Prolog-Regeln aufzurufen und zu verarbeiten (Programmbeispiele finden sich bei RATH 1995b). Ferner standen einzelne Bildobjekte bis auf Pixelebene als Fakten in einer Datenbank zur Verfügung, die mit Hilfe der üblichen Prolog-Mechanismen Backtracking und Unifikation ausgewertet werden konnten. Die Auswertemodelle wurden entweder mit dem neuronalen Netzsimulator *SNNS* (ZELL et al. 1994) -ebenfalls unter dem Betriebssystem *Limix* - oder mit *SAS* (SAS 1994) entwickelt. Der wissensbasierte Ansatz sowie die Ansätze basierend auf der Fuzzy-Logik und der Mittelwertansatz wurden in Pascal programmiert.

Die Bildaufnahme und Speicherung erfolgte auf einem konventionellen 486er Personal-Computer mit 50 Mhz und 5 Gbyte Festplatte. Zur Entwicklung und Verwendung der Auswertemodelle wurden PC's mit Taktraten zwischen 50 - und 130 Mhz eingesetzt.

## 6. Ergebnisse

### 6.1 Ergebnisse der entwickelten Algorithmen zur Merkmalsextraktion

#### 6.1.1 Allgemeines

Grundvoraussetzung für die computerbildanalytischen Pflanzenidentifikation ist die Erkennung artspezifischer botanischer Pflanzenmerkmale. Aufgrund der großen Variabilität der Pflanzen ist es notwendig, genau zu überprüfen, inwieweit an Einzelobjekten entwickelte Algorithmen zur Merkmalsextraktion generalisierbar und auf andere Objekte übertragbar sind. Ferner ist von zentraler Bedeutung, inwieweit die entwickelten Algorithmen grundsätzlich in der Lage sind, botanische Unterscheidungsmerkmale zu parametrisieren. Abbildungen 6.1.1 bis 6.1.6 und Tabelle 6.1.1 geben Aufschluß über die Funktionalität der entwickelten Bildbearbeitungsalgorithmen in den Bereichen Blattstiel, Blattachse, Blattspitze, Einzelblättchen, Blattlappen und Blattrand (vgl. Kapitel 5.3).

#### 6.1.2 Ergebnisse zur Blattstiel- und Blattachsenerkennung

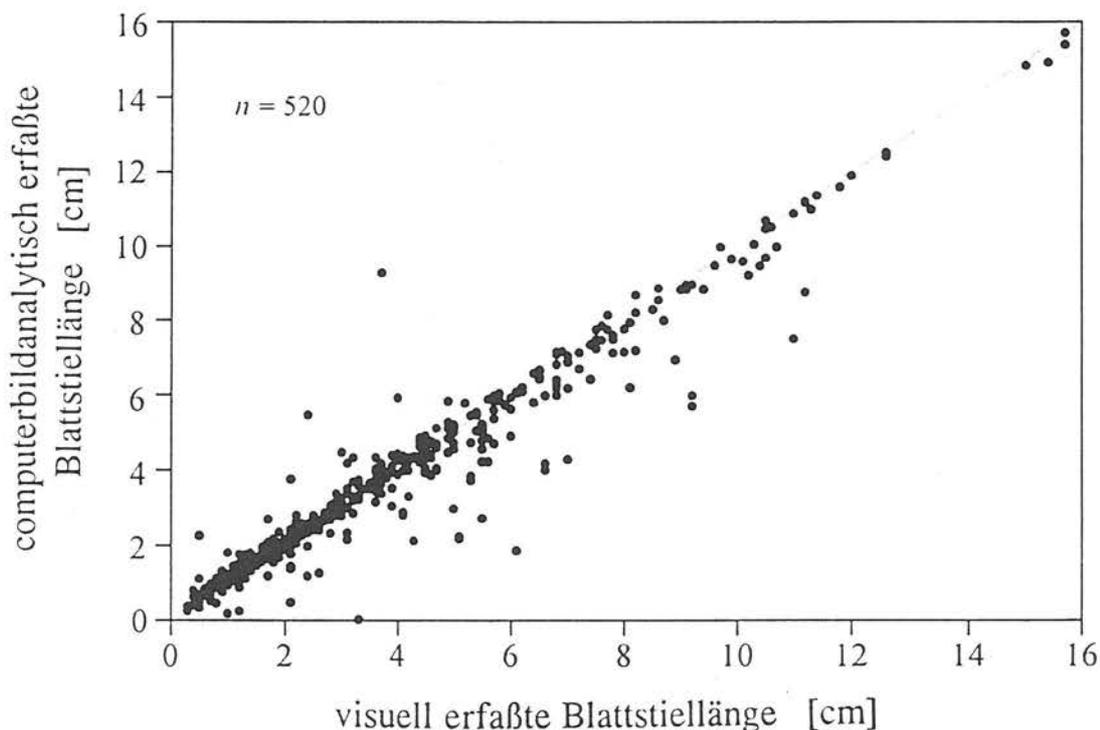


Abb. 6.1.1: Visuell und computerbildanalytisch erfaßte Blattstiellängen

Abbildung 6.1.1 zeigt die Übereinstimmung zwischen computerbildanalytisch ermittelten und realen Blattstiellängen der Blätter. Die realen Blattstiellängen wurden per Hand nachgemessen, wobei - im Gegensatz zur algorithmischen Erkennung - Stielkrümmungen berücksichtigt wurden. Es wird deutlich, daß eine sehr gute Übereinstimmung zwischen rechnergestützten und manuell erfaßten Blattstiellängen für den überwiegenden Teil der Blätter existiert. Leichte Abweichungen von weniger als 0,5 cm wurden durch Stielkrümmungen, durch unterschiedliche Interpretation des Stielansatzpunktes und durch unscharfe Bildaufnahmen (bedingt durch die Dicke des Stieles) verursacht. Aus Abbildung 6.1.1 wird auch ersichtlich, daß bei einigen Blättern größere Abweichungen auftraten, die nicht durch die obigen Fehler erklärbar sind. In diesen Fällen wurden z.B. zum Stiel noch Blattteile hinzugerechnet, die Blattspitze mit dem Blattstiel verwechselt, Teile der Rachis (Spindel) noch zum Stiel hinzugerechnet oder Teile der Rachis als Gesamtstiel interpretiert. Bei einigen Blättern existierten erhebliche Abweichungen ( $> 2$  cm), die sogar die weitere Verwendung dieser Daten zweifelhaft erscheinen ließen. Wesentliche Ursache der großen Abweichungen ist, daß aufgrund des Blatt- und Stielwachses in der Draufsicht Stielabschnitte oder der gesamte Stiel hinter, direkt neben oder vor der Blattspreite lagen und damit im Binärbild nicht oder nur unzureichend zu erkennen waren. Da für die weitere Bearbeitung der Blätter zumindest ein Stielansatzpunkt notwendig war, um die Lage des Blattes zu bestimmen, führten besonders nicht sichtbare Stiele zu erheblichen Fehlinterpretationen, da irgendeine andere Blattausbuchtung oder die Rachis als Stiel interpretiert wurde. Dieser Zustand trat besonders bei zusammengesetzten Blättern und Blättern mit abknickend wachsenden Stielen auf (vgl. Prinzipskizze Abbildung 6.1.2).

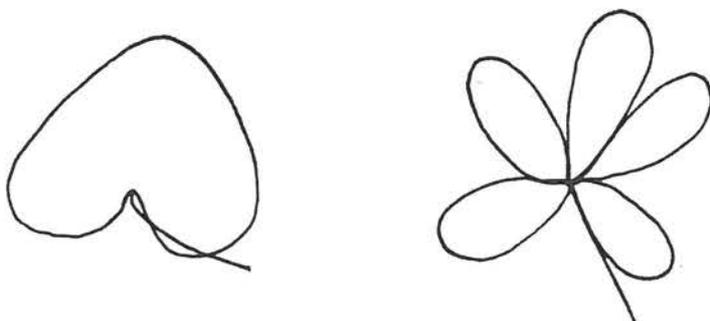


Abb. 6.1.2 : Prinzipskizze schwierig zu erfassender Blattstiele

Neben den direkt aus Abbildung 6.1.1 und 6.1.2 ersichtlichen Unzulänglichkeiten des Algorithmus existieren noch Fehler, bei denen kleine bzw. kurze Blattstiele mit Grannen, Blattspitzen o.ä. verwechselt wurden. Obwohl in diesen Fällen die Meßfehler in der Regel relativ klein sind, haben sie eventuell große Auswirkung, da insbesondere die Erkennung und Bestimmung der Blattachse, der Blattbasis und der Blattspitze von der Lage des Blattstieles (egal welche Länge) abhängt.

Die Wirksamkeit der entwickelten Algorithmen muß daher in Verbindung mit der Bestimmung der Lage und Ausrichtung der Blattachse bewertet werden. In einigen Fällen erfolgte trotz ungenauer oder falscher Stielerkennung eine richtige Berechnung der Blattachse, da die Lage des Stieles prinzipiell richtig erkannt wurde. In anderen Fällen erfolgte trotz richtiger Stielerkennung eine falsche Achsenberechnung, da z.B. eine Blattlappenspitze rechnerisch richtig, sachlich aber falsch als Blattspitze interpretiert wurde. Teilweise lagen auch aufgrund der Blattgeometrien keine richtigen Blattspitzen vor, die den Endpunkt der Blattachse anzeigen konnten (z.B. *Liriodendron tulipifera*).

Tabelle 6.1.1 quantifiziert zusammenfassend die Güte der entwickelten Algorithmen zur Stielerkennung und -vermessung und zur Blattachsenbestimmung. Es wird zwischen korrekten, einsetzbaren und unbrauchbaren Ergebnissen bei einfachen und zusammengesetzten Blättern unterschieden. In 2 % der Fälle waren sowohl die Ergebnisse der Stielerkennung als auch die Blattachsenidentifikation unbrauchbar. Bei diesen Blättern ist davon auszuge-

Tab. 6.1.1: Bewertung der Algorithmen zur Blattstiel- und Blattachsenerfassung

	S+,A+ [%]	S+-,A+ [%]	S-,A+- [%]	S-,A- [%]
einfache Blätter	92	4	3	1
zusammengesetzte Blätter	74	18	4	4
alle Blätter	88	7	3	2

- S: Erfassung des Blattstieles
- A: Erfassung der Blattachse
- +: Erfassung und Ergebnisse korrekt
- + -: Erfassung mit leichten Mängeln, Ergebnisse einsetzbar
- : Erfassung falsch, Ergebnisse unbrauchbar

hen, daß die auf der Blattachse und dem Blattstiel aufbauenden Blattmerkmale  $\varphi_{15} - \varphi_{22}$  falsch berechnet wurden. In 3 % aller Fälle waren die Ergebnisse der Stielerkennung falsch, jedoch die berechnete Blattachse war noch einsetzbar (d.h. keine zu große Abweichung von der visuell bestimmten Blattachse). Bei 88 % der Blätter wurde eine korrekte Funktion der Algorithmen festgestellt. In 7 % der Fälle waren leichte Abweichungen der Blattstiellängen zu verzeichnen, die aber keine Auswirkung auf die Blattachsenbestimmung hatten. Betrachtet man die Ergebnisse für einfache und zusammengesetzte Blätter getrennt, ist festzustellen, daß die Blattstielerkennung besonders bei zusammengesetzten Blättern zu Problemen führen kann. Dieses ist mit der oben aufgeführten Stiel-Blattüberlappung oder mit den speziell für zusammengesetzte Blätter entwickelten Algorithmen (siehe 5.3.2) zu erklären. Der Anteil an richtiger Blattstielerkennung reduzierte sich hierdurch auf 74 %.

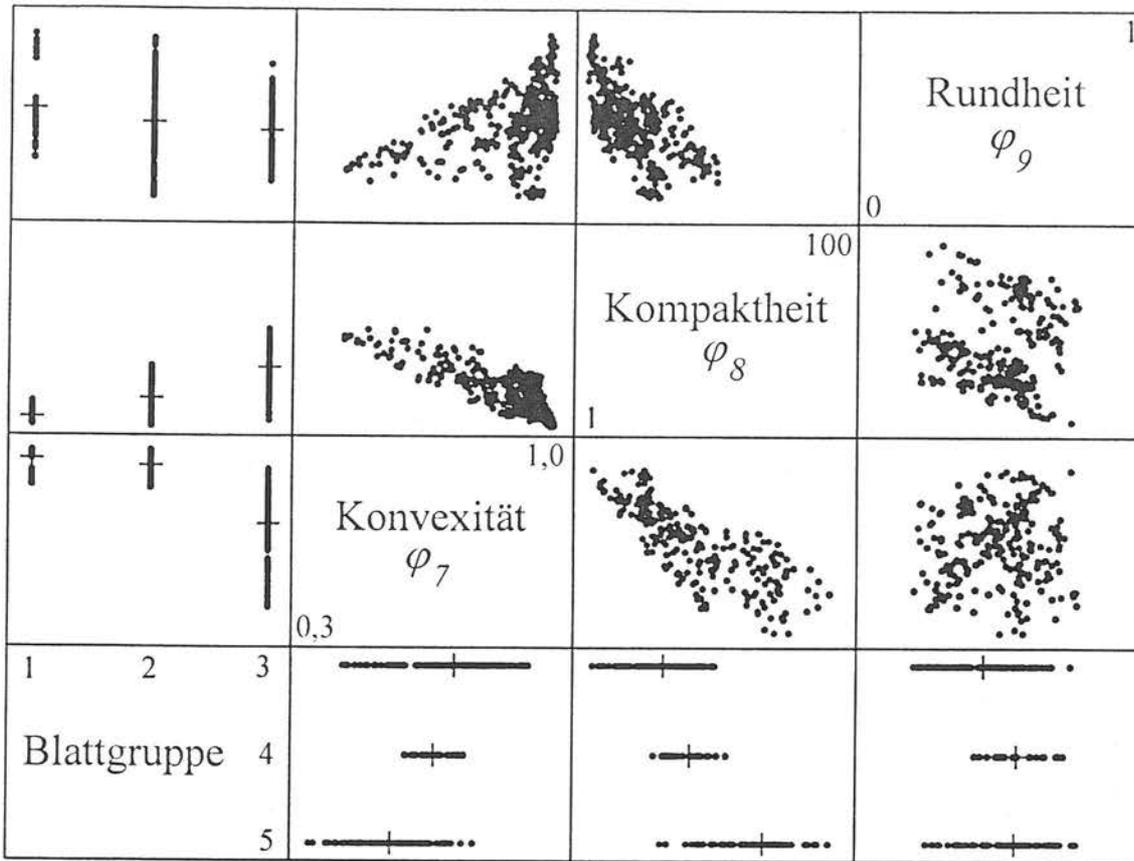
### 6.1.3 Ergebnisse zur Formerkennung der Blattspreite, zur Blattanzahlberechnung, zur Blattlappenerkennung und zur Blattrandanalyse

Die Ausprägung der Blattspreite ist ein wesentliches botanisches Merkmal zur Unterscheidung der Arten. Abbildung 6.1.3 stellt den Zusammenhang zwischen wesentlichen Formparametern ( $\varphi_7 - \varphi_9$ ) und botanisch bedingten Blattgruppen nach GODET (1987) dar.

Im einzelnen werden die Blattgruppen

- ganze, ganzrandige Laubblätter (Blattgruppe 1, Abb. 6.1.3)
- ganze, gesägte/gezähnte und/oder gekerbte Laubblätter (Blattgruppe 2, Abb. 6.1.3)
- ganze, gelappte Laubblätter (Blattgruppe 3, Abb. 6.1.3)
- zusammengesetzte, gefingerte Laubblätter (Blattgruppe 4, Abb. 6.1.3)
- zusammengesetzte, gefiederte Laubblätter (Blattgruppe 5, Abb. 6.1.3)

unterschieden. Die Felder im linken oberen Dreieck der Abbildung stellen die Werteverteilungen der Blattgruppen 1, 2 und 3 dar. Die anderen Felder beinhalten die Werte der Gruppen 3, 4 und 5. Es wird deutlich, daß anhand der Konvexität ( $\varphi_7$ ) eine Differenzierung zwischen den Blattgruppen 1+2 und 3+4+5 möglich ist. Eine weitergehende botanisch begründete Unterscheidung der einzelnen Gruppen (besonders zwischen gelappten und gefiederten Blättern) ist nur in Verbindung mit der Kompaktheit ( $\varphi_8$ ) möglich.



+ = Mittelwert, Kompaktheit mit logarithmischer Skala

Abbildung 6.1.3: Formparameter botanischer Blattgruppen (Gruppenerklärung im Text)

Relativiert wird dieses jedoch durch die Korrelation zwischen Konvexität und Kompaktheit. Die Rundheit ( $\varphi_9$ ) trägt, über alle Blattgruppen gesehen, nur wenig zur direkten Beschreibung botanischer Merkmale bei. Im Einzelfall, der aus Abbildung 6.1.3 nicht hervorgeht, können jedoch nicht zuletzt auch aufgrund der geringeren Korrelation zwischen Rundheit und Konvexität bzw. Kompaktheit evtl. gute Trenneigenschaften des Parameters ( $\varphi_9$ ) vorliegen. Zusammenfassend läßt sich sagen, daß aus den ermittelten Formparametern in der Regel nicht unmittelbar, sondern nur in Kombination mit anderen Merkmalen botanische Form- und Trennmerkmale abgeleitet werden können. Ähnliche Aussagen lassen sich auch für die Parameter  $\varphi_{10} - \varphi_{11}$ ,  $\varphi_{17} - \varphi_{18}$  und  $\varphi_{21} - \varphi_{22}$  aufstellen.

Abbildung 6.1.4 gibt die vom Computer bestimmte Blättchenanzahl in Abhängigkeit von der real vorliegenden und visuell überprüften Blättchenanzahl wieder. Da es sich bei der Stichprobe um 410 ganze und 110 zusammengesetzte Blätter handelt und da genau 410 mal

der tatsächlichen Blattanzahl 1 auch die bildanalytisch erfaßte Blattanzahl 1 zugeordnet wurde, wurde offensichtlich eine exakte Unterscheidung zwischen diesen beiden Blattgruppen durchgeführt. Der in Kapitel 5.3.5 beschriebene Algorithmus kann somit in dieser Hinsicht als optimal bewertet werden. Bei der Bestimmung der Blättchenzahl der zusammengesetzten Blätter entstanden zum Teil Abweichungen, die auf Blattüberlappungen, Einkerbungen oder Fehlinterpretationen von sehr kleinen Blättchen beruhen.

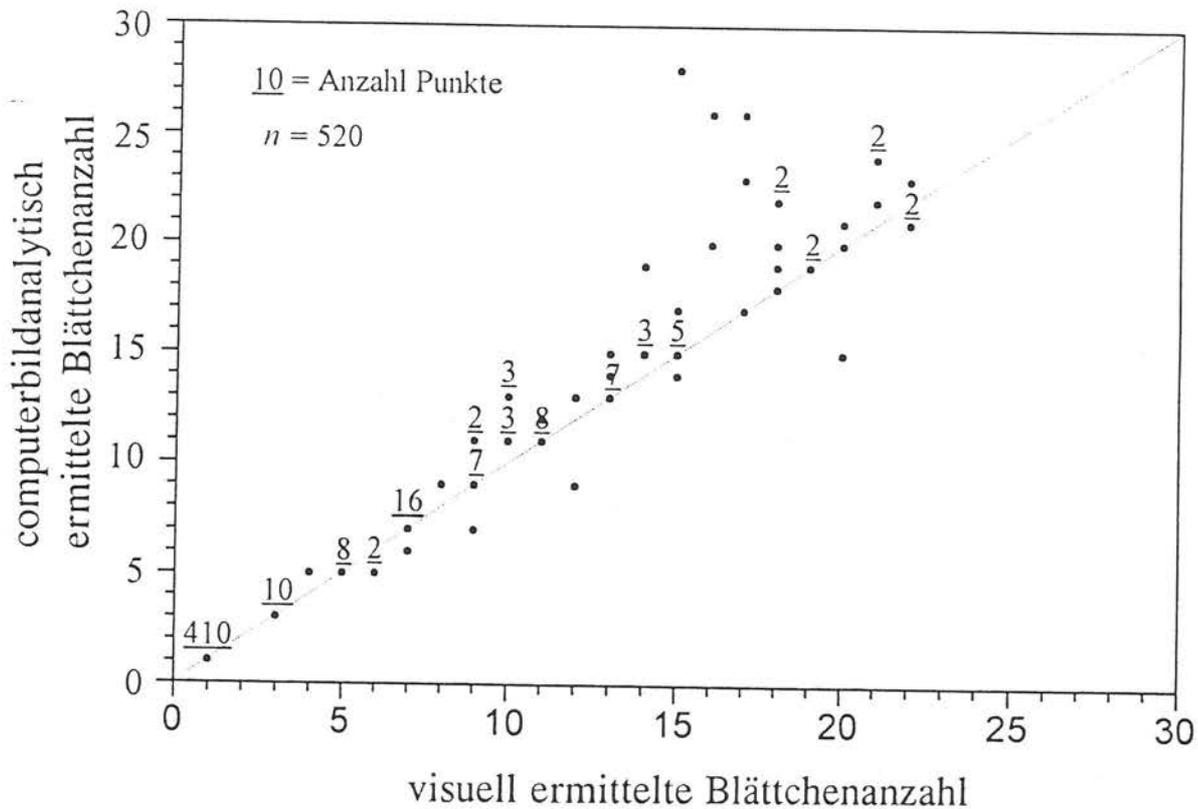


Abbildung 6.1.4: Computerbildanalytisch und visuell überprüfte Blättchenanzahl

Abb. 6.1.4 verdeutlicht, daß trotz optimierter Justierung des entwickelten Algorithmus bei stark gefiederten Blättern die Einzelblätter zu stark unterteilt und somit die Blättchenanzahl überschätzt wird. Durch Veränderung einiger Konstant-Parameter des Algorithmus (siehe  $\lambda_1 - \lambda_5$ , Kap. 5.3.5) konnte dieses Verhalten unterdrückt werden, jedoch erfolgte dann eine deutliche Unterschätzung der Blättchenanzahl, besonders bei gering gefiederten Blättern. Da die in Abbildung 6.1.4 aufgezeigten Abweichungen innerhalb der Pflanzenarten relativ einheitlich sind, behindern sie nicht den Klassifikationsprozeß und sind aus dieser Sicht zu tolerieren. Insgesamt ist der entwickelte Algorithmus zur Bestimmung der Blättchenanzahl

einsetzbar und liefert adäquate, auf den botanischen Blattunterschieden aufbauende und im Klassifikationsprozeß gut nutzbare Informationen.

Eine Bewertung des Algorithmus zur Erfassung der Blattlappigkeit und zur Bestimmung der Anzahl der Blattlappen ist schwieriger als im Fall der Blättchenanzahlbestimmung, da keine klar definierten Vergleichsmaßstäbe vorliegen. Insbesondere ist die Differenzierung zwischen Blattlappen, großen Blattzähnen und tief eingeschnittenen Blättern problematisch und in der Regel rein subjektiv. Selbst die Bestimmungsschlüssel von FITSCHEN (1994) und GODET (1987) bewerten die Anzahl der Blattlappen einiger Arten unterschiedlich. Abbildung 6.1.5 verzichtet daher auf die Gegenüberstellung von rechnergestützter Blattlappenerfassung und visueller Überprüfung. Stattdessen wird die bildanalytisch bestimmte Lappenanzahl aller Blätter aufgeführt, die zu einer Blattgruppe gehören, in der mindestens ein Blatt aufgrund der Konvexität als lappig identifiziert (siehe Kap. 5.3.6) wurde.

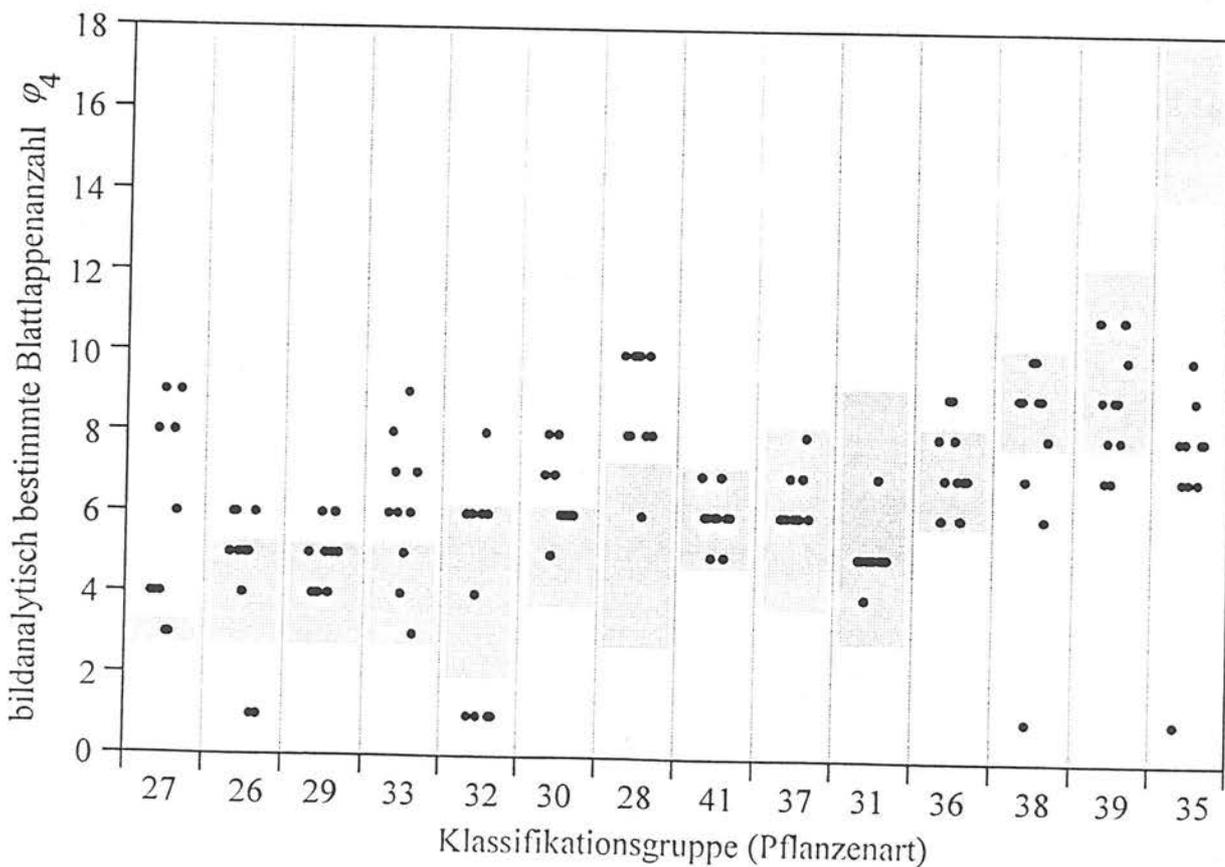


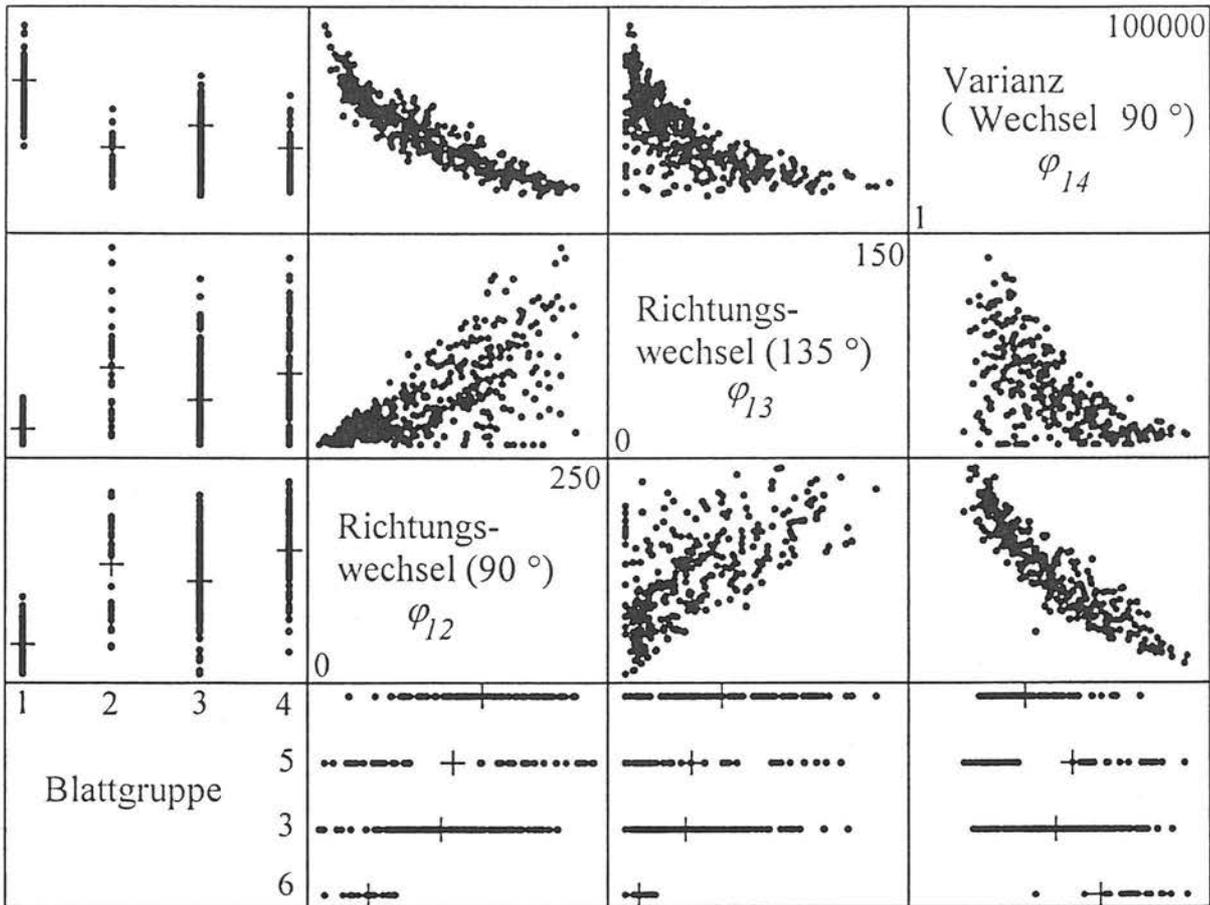
Abbildung 6.1.5: Bildanalytisch bestimmte Blattlappenanzahl verschiedener Arten

Die grau hinterlegten Spannweiten geben die von GODET (1987) bzw. - falls GODET (1987) keine Angaben macht - die von FITSCHEN (1994) angegebenen Bereiche wieder. Die auf der Abszisse aufgetragenen Blattgruppennummern entsprechen den im Anhang aufgeführten Pflanzenarten. Man erkennt, daß bei einigen Arten sowohl Blattlappenzahlen von 1 und  $> 1$  auftreten, was aus der Tatsache resultiert, daß bei einer hohen Konvexität der Algorithmus zur Bestimmung der Lappenanzahl gar nicht ausgeführt wird, sondern das Blatt als nicht gelappt und mit einer Standardlappenanzahl von 1 interpretiert wird. Eine alleinige Auswertung des Parameters  $\varphi_4$  führt in diesen Fällen zu ungünstigen Ergebnissen, da große Spannweiten der Werte innerhalb der jeweiligen Gruppe auftreten. Werden innerhalb der Auswertemodelle die Werte des Parameters  $\varphi_4$  mit der Konvexität  $\varphi_7$  kombiniert, spielt eine innerhalb der gelappten Blattgruppen auftretende Lappenzahl von 1 eine nicht so bedeutende Rolle. Sie trägt dann allerdings auch nur unwesentlich zur Unterscheidung von anderen Blattgruppen bei. Betrachtet man bei Abbildung 6.1.5 nur die Ergebnisse der als gelappt identifizierten Blätter, so ergibt sich eine relativ gute Einheitlichkeit der Werte innerhalb der einzelnen Gruppen. Ausnahme bilden hier die Gruppe 27 (*Acer ginnala*) und die Gruppe 33 (*Platanus x acerifolia*), die durch ihre sehr unterschiedlichen Wuchsformen einen breiten Wertebereich abdecken. Ansonsten repräsentieren die Ergebnisse gut die Artenunterschiede und stimmen zumindest in ihrer Tendenz mit den in den botanischen Schlüsseln angegebenen Kennzahlen überein. Eine direkte Nutzung der Spannweiten aus den Bestimmungsschlüsseln ist aber nicht möglich.

Wesentliches Kriterium zur Unterscheidung der Arten ist die Ausprägung der Blattrandfeinstruktur. Abbildung 6.1.6 stellt die Ergebnisse der Algorithmen zur Parametrisierung des Blattrandes am Beispiel ausgewählter Blattrandformen zusammenfassend dar. Auf der waagerechten Achse des Blattgruppenfeldes sind vier wesentliche Blattrandhauptgruppen nach GODET (1987) angegeben, für deren Blätter Blattrandanalysen durchgeführt wurden. Die dazugehörigen Werteverteilungen sind in den Feldern des linken oberen Dreieckes der Abbildung dargestellt. Im einzelnen gilt:

- Blattgruppe 1: ganzrandige Blätter
- Blattgruppe 2: gezähnte Blätter
- Blattgruppe 3 gesägte Blätter

- Blattgruppe 4: doppelt gesägte Blätter.



+ = Mittelwert, Varianz mit logarithmischer Skala

Abbildung 6.1.6: Blattrandparameter botanischer Blattgruppen (Gruppenerklärung im Text)

Es wird deutlich, daß anhand der Anzahl der Richtungswechsel (90 ° und 135 °) Aussagen über das Nicht-Vorliegen eines ganzrandiges Blattes getroffen werden können, da ganzrandige Blätter immer nur eine geringe Anzahl an Richtungswechseln vorweisen. Parameter  $\varphi_{14}$  kann diese Aussagen verstärken oder abschwächen. Eine alleinige Verwendung von Parameter  $\varphi_{14}$  scheint jedoch nicht sinnvoll, da die Trenn- oder Ausschlußschärfe dieses Parameters - über alle Gruppen gesehen - gering ist. Im Einzelfall, d.h. für eine Pflanzengruppe, kann Parameter  $\varphi_{14}$  eventuell wertvolle Informationen zur Arten-Diskriminierung liefern. Erschwert wird dieses allerdings durch die hohen Korrelationen zwischen den dargestellten Parametern. Eine weitergehende direkte Gruppenunterscheidung der Gruppen 2, 3

und 4 ohne Kombination der einzelnen Blattrandparameter, ist, wie aus Abb. 6.1.6 hervorgeht, mit den eingesetzten Verfahren nicht möglich.

Ergebnisse der Untersuchungen zur weitergehenden Analyse des Blattrandes mit Hilfe der entwickelten Algorithmen zeigt die Abbildung unterhalb der Links-unten-rechts-oben-Diagonalen. Die senkrechte Achse des Gruppenfeldes wurde hier mit den Blattgruppen

- Blattgruppe 4 (doppelt gesägt)
- Blattgruppe 5 (gesägt bis doppelt gesägt)
- Blattgruppe 3 (gesägte Blätter)
- Blattgruppe 6 (kerbig gesägte Blätter)

belegt. Es handelt sich somit um Feinunterteilungen der Blattrandform „gesägt“.

Ähnlich wie im vorherigen Fall kann beim Vorliegen bestimmter Bedingungen die Zugehörigkeit zur Gruppe 6 ausgeschlossen werden. Dies wird jedoch durch die Tatsache relativiert, daß die Blattrandparameter der Gruppe 6 nur aus 20 Blättern resultieren, die eventuell keinen repräsentativen Querschnitt darstellen. Weitere unmittelbare Unterscheidungen sind anhand Abbildung 6.1.6 nicht zu erkennen, so daß eine über die Blattrandgrobstruktur hinausgehende und für alle Arten generalisierbare Parametrisierung botanischer Blattrandstrukturen nur unzureichend möglich ist. Untersuchungen zur Verwendung mehrerer miteinander kombinierter Parameter ergaben eine Verbesserung der Parametrisierung der Blattrandstruktur. Auf diese wird an dieser Stelle aber nicht weiter eingegangen, da auf die Bildung spezieller Einzelparameterauswertemodelle innerhalb der Arbeit generell verzichtet wird.

## 6.2 Allgemeine statistische Kennzahlen der Merkmalextraktion

Tab. 6.2.1 gibt die empirischen F-Werte und die empirischen Variationskoeffizienten der computerbildanalytisch extrahierten Merkmale wieder. Die Variationskoeffizienten wurden für jede Unterscheidungsgruppe (Pflanzenart) berechnet und anschließend über alle Gruppen gemittelt.

Tab. 6.2.1: Statistische Kennzahlen bildanalytisch erfaßter Blattparameter

	Parameter											
	$\varphi_2$	$\varphi_3$	$\varphi_4$	$\varphi_5$	$\varphi_6$	$\varphi_7$	$\varphi_8$	$\varphi_9$	$\varphi_{10}$	$\varphi_{11}$	$\varphi_{12}$	
$f_{emp.}$	-	330	79	52	211	189	80	93	141	109	68	
$v_{emp.}$	-	12,4	26,1	28,9	9,4	4,5	14,3	10,1	18,5	5,1	28,5	
	Parameter											
	$\varphi_{13}$	$\varphi_{14}$	$\varphi_{15}$	$\varphi_{16}$	$\varphi_{17}$	$\varphi_{18}$	$\varphi_{19}$	$\varphi_{20}$	$\varphi_{21}$	$\varphi_{22}$		
$f_{emp.}$	20	8	44	33	24	36	41	81	84	32		
$v_{emp.}$	55,7	68,1	26,1	20,8	7,3	9,5	21,2	14,6	5,0	8,0		

$f_{emp.}$ : empirischer f-Wert

$v_{emp.}$ : empirischer Variationskoeffizient (gemittelt über die Gruppen)

(Berechnungen siehe DUFNER et al. 1992)

Bei allen Parametern gilt mit 1 %iger Irrtumswahrscheinlichkeit, daß die Erwartungswerte des jeweiligen Parameters über die Gruppen nicht gleich sind (Shapiro-Wilk-Test, siehe DUFNER et al. (1992)). Das heißt, daß die ermittelten Parameter zumindest bei einzelnen Pflanzengruppen zur Gruppenunterscheidung beitragen und eingesetzt werden können. Betrachtet man die F-Werte der einzelnen Merkmale genauer, ergibt sich, daß die Blättchenanzahl ( $\varphi_3$ ) und die Formparameter  $\varphi_6$ ,  $\varphi_7$ ,  $\varphi_{10}$  und  $\varphi_{11}$  eine hohe Differenzierungsgüte mit F-Werten über 100 aufweisen. Zwei der drei Parameter der Kettencodanalyse haben mit F-Werten  $\leq 20$  nur eine geringe Unterscheidungswirkung und sind wahrscheinlich nur in Einzelfällen verwendbar. Bei der Bewertung der F-Werte muß allerdings beachtet wer-

den, daß sich die Werte nur auf die Einzelwirkung einzelner Parameter beziehen und die kombinatorische Wirkung mehrerer Parameter nicht berücksichtigt wird.

Die zweite Zeile der Tabelle 6.2.1 stellt die durchschnittlichen Variationskoeffizienten der einzelnen Parameter innerhalb der Gruppen dar. Parameter mit großen F-Werten weisen geringere Streuungen auf als die anderen. Nach PRECHT (1987) ist bei der Verwendung von Parametern, die einen Variationskoeffizienten über 50 haben, Vorsicht geboten, da sehr inhomogene Verteilungen vorliegen. Insbesondere sollte das arithmetische Mittel zur Verdichtung der Daten möglichst nicht verwendet werden. Aus der Tabelle wird ersichtlich, daß diese Tatsache besonders auf die Blattrandmerkmale  $\varphi_{13}$  und  $\varphi_{14}$  zutrifft.

Tab. 6.2.2: Statistische Kennzahlen bildanalytisch erfaßter Blattparameter

	Parameter										
	$\varphi_2$	$\varphi_3^*$	$\varphi_4^\#$	$\varphi_5$	$\varphi_6$	$\varphi_7$	$\varphi_8$	$\varphi_9$	$\varphi_{10}$	$\varphi_{11}$	$\varphi_{12}$
n [%]	-	50	21	71	79	77	83	83	83	88	88
$s_{emp.}$	-	0,09	-0,11	0,09	0,32	-0,04	0,25	-0,11	0,19	-0,05	0,04
$w_{emp.}$	-	0,28	0,89	-0,16	0,11	0,29	0,61	-0,27	0,36	0,07	-0,23
	Parameter										
	$\varphi_{13}$	$\varphi_{14}$	$\varphi_{15}$	$\varphi_{16}$	$\varphi_{17}$	$\varphi_{18}$	$\varphi_{19}$	$\varphi_{20}$	$\varphi_{21}$	$\varphi_{22}$	
n [%]	63	46	75	62	77	79	71	75	62	75	
$s_{emp.}$	0,47	1,17	0,11	0,51	-0,26	0,15	0,23	0,40	-0,46	-0,14	
$w_{emp.}$	0,46	1,59	0,17	0,57	0,06	0,16	0,34	0,24	0,61	0,26	

n: Anteil der Klassifikationsgruppen (Gruppengesamtanzahl = 52), bei denen die Normalverteilungsannahme innerhalb der Gruppen nicht verworfen wird (Shapiro-Wilk-Test, mit Irrtumswahrscheinlichkeit  $\alpha = 10\%$ )

$s_{emp.}$ : empirische Schiefe der Verteilung (gemittelt über die Gruppen)

$w_{emp.}$ : empirische Wölbung der Verteilung (gemittelt über die Gruppen)

\* Berechnungen auf der Basis von 11 Gruppen (zusammengesetzte Blätter)

# Berechnungen auf der Basis von 14 Gruppen (gelappte Blätter)

(Berechnungen siehe DUFNER et al. 1992)

Tabelle 6.2.2 stellt weitere statistische Kennzahlen, die Hinweise auf die zu verwendenden Auswertemodelle geben, dar. Zeile 1 gibt den Anteil der Klassifikationsgruppen an, bei dem von einer Normalverteilung der Parameterwerte innerhalb der Gruppen ausgegangen werden kann. Bei einer von DUFNER et al. (1992) vorgeschlagenen Irrtumswahrscheinlichkeit von 10 % muß offensichtlich für alle Parameter zumindest für einzelne Pflanzenarten (Unterscheidungsgruppen) die Normalverteilungsannahme verworfen werden.

Zeile 2 stellt die empirische Schiefe der jeweiligen Verteilung innerhalb der Gruppen dar (gemittelt über alle Gruppen). Es wird deutlich, daß einige Parameter statistisch gesehen ungünstige Verteilungen aufweisen, die z.B. die Verwendung des arithmetischen Gruppenmittels als Verdichtungsmaßzahl problematisch machen. Besonders auffällig sind hierbei die schiefen Verteilungen der Parameter  $\varphi_{14}$ ,  $\varphi_{16}$ ,  $\varphi_{13}$ ,  $\varphi_{21}$  und  $\varphi_{20}$ . Als Ursache kommt die große Variabilität der Blätter, eine fehlerhafte Wertberechnung (s. Kap. 5.3) oder die geringe Anzahl an Versuchsblättern pro Gruppe in Frage. Zeile 3 zeigt die empirische Wölbung (Kurtosis) innerhalb der Gruppen. Beim überwiegenden Teil der Parameter deutet eine Wölbung  $> 0$  darauf hin, daß steilgipfelige Verteilungen mit einer größeren Anzahl an großen Abweichungen vom arithmetischen Mittelwert (im Vergleich zu der Normalverteilung mit gleicher Streuung) vorliegen. Lediglich die Parameter Pixelfläche  $\varphi_5$ , Rundheit  $\varphi_9$  und der Blattrandparameter  $\varphi_{12}$  - alle mit Wölbungsmaßen  $< 0$  - repräsentieren flachgipfeligere Verteilungen (im Vergleich zu einer Normalverteilung mit gleicher Streuung), die sich nicht deutlich auf einen Mittelwert konzentrieren und damit ungünstige Klassifikationsvariablen darstellen. Bei der Interpretation der Werte in Zeile 2 und 3 muß berücksichtigt werden, daß die dargestellten Werte Mittelwerte über alle Gruppen darstellen, die die einzelnen Parameter charakterisieren sollen. Zwischen den Gruppen treten deutliche Schwankungen auf.

Abbildung 6.2.1 stellt die lineare Korrelation aller Parameter anhand Pearsonscher Korrelationskoeffizienten grafisch dar. Für jeden Parameter sind die Korrelationen mit den übrigen 20 Parametern aufgeführt ( $21 \cdot 20 = 420$  Werte). Die zu jeweils zwei Parametern gehörende Korrelation läßt sich anhand der Abbildung ablesen, wenn zu einem Punkt eines Parameters ein zweiter Punkt mit gleichem Korrelationswert (des anderen Parameters) zugeordnet wird.

In die Grafik wurden die Zufallshöchstwerte (vgl. PRECHT 1987) bei einem  $\alpha = 5\%$  und  $\alpha = 1\%$  als Linien eingezeichnet.

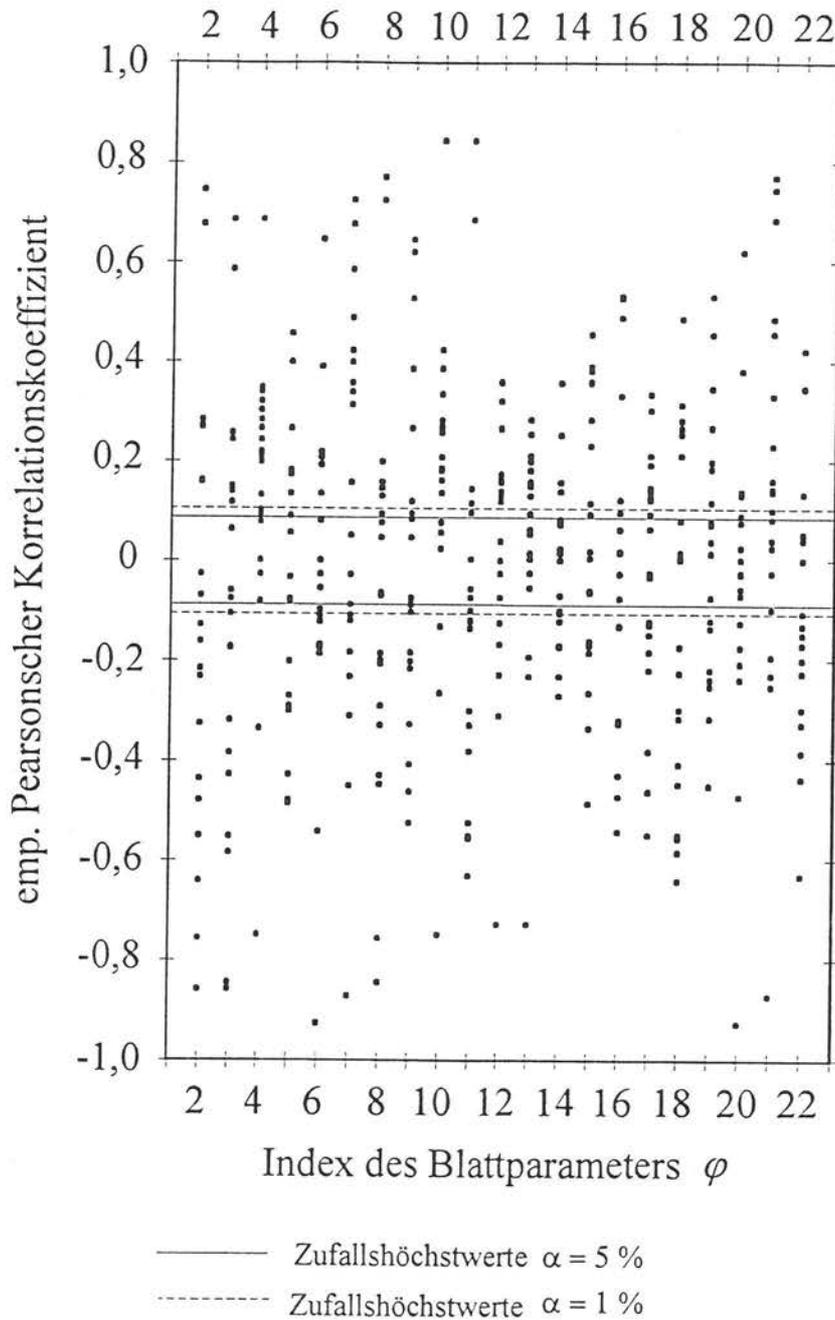


Abbildung 6.2.1: Korrelationskoeffizienten berechneter Blattparameter

90 der 420 Werte liegen innerhalb des 5 %-Bereiches. Das heißt, daß bei ihnen von einer zufälligen Korrelation ausgegangen werden kann. 330 Werte liegen außerhalb dieses Bereichs. Bei ihnen liegt eine statistisch gesicherte lineare Korrelation zwischen den jeweiligen

Parametern vor. Besonders auffällig, aber auch inhaltlich erklärbar, ist z.B. die hohe lineare Korrelation (mit Korrelationskoeffizienten über 0,8 oder unter -0,8) des Parameters  $\varphi_6$  (Länge zu Breite Spreite) mit Parameter  $\varphi_{20}$  (Länge zu Breite Spreitenbasis), des Parameters  $\varphi_7$  (Konvexität Blattspreite) mit Parameter  $\varphi_{21}$  (Konvexität Spreitenbasis), des Parameters  $\varphi_2$  (Blattaufbau) mit Parameter  $\varphi_3$  (Blättchenanzahl), des Parameters  $\varphi_3$  (Blättchenanzahl) mit Parameter  $\varphi_8$  (Kompaktheit Spreite) oder des Parameters  $\varphi_{10}$  (Elliptizität Blattspreite) mit Parameter  $\varphi_{11}$  (Eckigkeit Blattspreite). Insgesamt wird aus Abbildung 6.2.1 deutlich, daß es sich bei den ermittelten Blattparametern in vielen Fällen um stark untereinander korrelierende Werteverteilungen handelt. Hinzu kommt, daß in einigen Fällen auch nicht lineare Korrelationen auftreten (siehe z.B. Abb. 6.1.6).

### 6.3 Größen- und Lageinvarianz der Merkmale

Da die zu erkennenden Blätter nicht einheitliche Größen haben und sowohl kleine als auch große Blätter innerhalb der Arten vorkommen, ist die Verwendbarkeit der beschriebenen Blattparameter entscheidend von ihrer Invarianz gegenüber Größenunterschieden abhängig. Abbildung 6.3.1 stellt die empirischen Pearsonschen Korrelationskoeffizienten zwischen der Blattgröße in Form des Parameters  $\varphi_5$  (Pixelfläche) und den übrigen Parametern innerhalb der Pflanzenarten (Gruppen) dar. Auch hier wurden die Zufallshöchstwerte (vgl. PRECHT 1987) für  $\alpha = 5\%$  und  $\alpha = 1\%$  eingezeichnet. Die eingetragenen Punkte stellen einen oder mehrere Meßwerte dar. Größeninvarianzen können ausgeschlossen werden, wenn signifikante Korrelationen zwischen der Blattgröße und dem jeweiligen Parameter vorliegen.

Bei 17 von 20 Parametern liegen mehr als 80 % der Werte innerhalb des Zufallsbereiches ( $\alpha = 5\%$ ). Da sich zusätzlich keine klare Korrelationsrichtung (positiv oder negativ) erkennen läßt und da in der Regel sowohl einige Werte unterhalb als auch überhalb der Zufallsgrenze liegen, kann bei den 17 Parametern von Größeninvarianz ausgegangen werden. Ausnahme bildet der Parameter  $\varphi_3$  (Blättchenanzahl), bei dem viele positive Korrelationen auftreten. Da Blätter, bestehend aus vielen Einzelblättchen, in der Regel größere Pixelflächen haben als Blätter der gleichen Art mit weniger Blättchen, ist diese Korrelation botanisch bedingt und damit im Unterscheidungsprozeß auch nicht anders verwendbar.

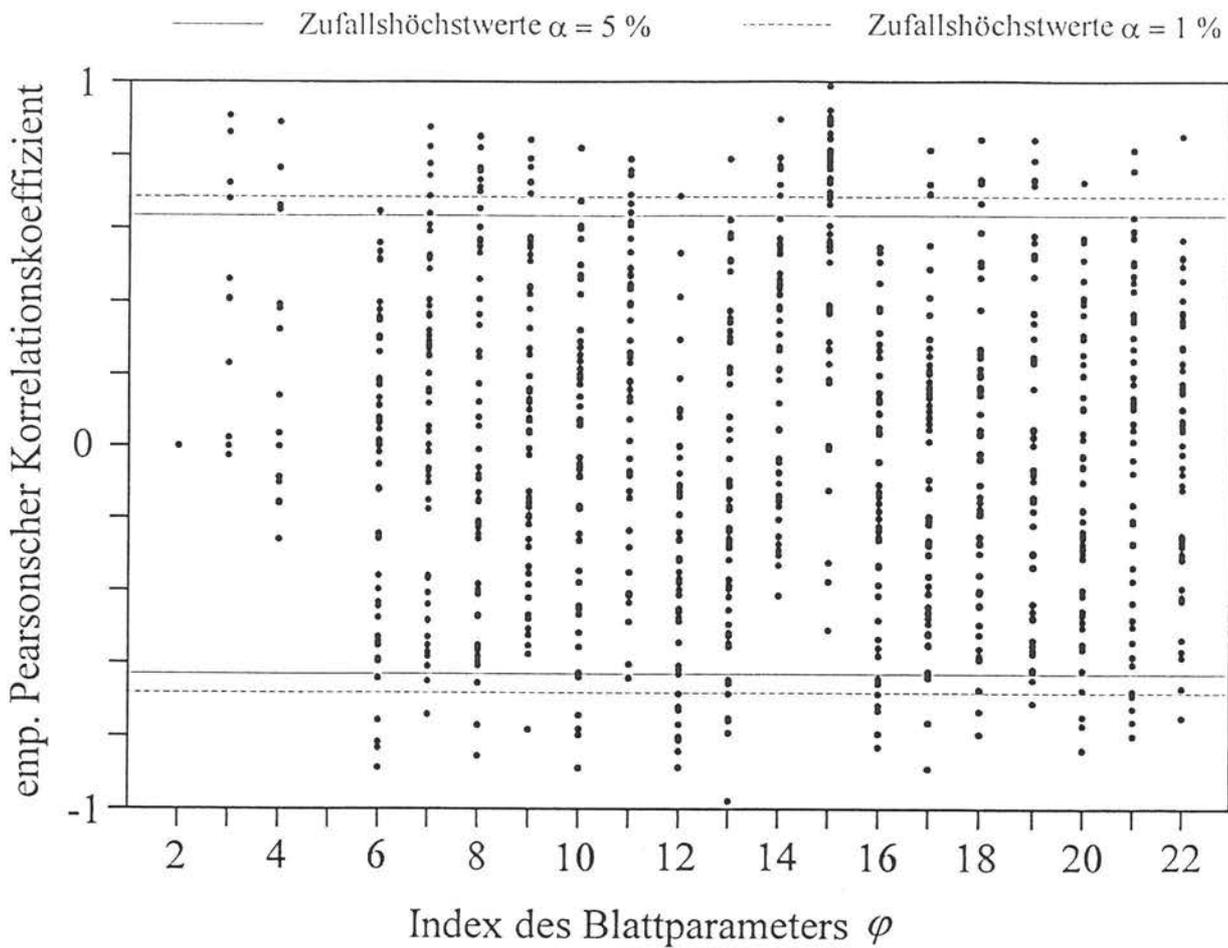


Abbildung 6.3.1 : Korrelation zwischen der Blattgröße und den übrigen Blattparametern innerhalb der Unterscheidungsgruppen (Pflanzenarten)

Bei Parameter  $\varphi_8$  (Kompaktheit Spreite) und beim Blattrandparameter  $\varphi_{12}$  liegen jeweils 23 % der Werte außerhalb des Zufallsbereiches. Bei Parameter  $\varphi_8$  sind die Werte über den positiven und den negativen Bereich relativ gleichmäßig verteilt, so daß von einer allgemeinen Größeninvarianz ausgegangen werden kann. Problematischer sieht es beim Blattrandparameter  $\varphi_{12}$  aus. Hier deutet die Verteilung auf eine negative Korrelation hin. Das heißt, größere Blätter neigen zu geringeren Richtungswechseln ( $90^\circ$ ) als kleinere Blätter der gleichen Art. Offensichtlich und aus der Art der Parameterberechnung erklärbar ist die Analyse des Kettencodes in der beschriebenen Form nicht immer größeninvariant. Dem gegenüber steht allerdings die Tatsache, daß die beiden weiteren Blattrandparameter  $\varphi_{13}$  und  $\varphi_{14}$  relativ gleichmäßige Verteilungen haben. Eindeutig größenabhängig ist der Para-

meter  $\varphi_{15}$  (Blattstiellänge) mit stark positiven Korrelationen. Da größere Blätter normalerweise auch größere Stiele haben, ergibt sich diese Korrelation nahezu von selbst und ist botanisch vorgegeben und im Klassifikationsprozeß ähnlich wie bei der Blättchenanzahl nicht zu ändern.

Neben der Größeninvarianz ist auch die Lageinvarianz der Parameter von zentraler Bedeutung, da nur so garantiert werden kann, daß die Auflagerichtung der Blätter auf dem Scanner für den Blatterkennungsprozeß keine Rolle spielt. Obwohl die entwickelten Algorithmen prinzipiell lageinvariant sind, existieren aufgrund der fest ausgerichteten Erosions-, Dilations- und Verschiebungsmasken Richtungsabhängigkeiten, die im Einzelfall zu Unterschieden bei den Blattparametern führen können. Zur Überprüfung der Lageinvarianz der Parameter wurde von jeder Unterscheidungsgruppe (Pflanzenart) ein Blatt ausgewählt, von dem zwei Bilder in unterschiedlichen Aufnahmerichtungen vorlagen. Anschließend wurden für alle Merkmale die absoluten Differenzen zwischen den beiden Aufnahmen berechnet und getestet, ob sich diese Differenzen signifikant von 0 unterscheiden (t-Test). Tabelle 6.3.1 stellt die Ergebnisse dar.

Tab. 6.3.1: Werte zur Beurteilung der Lageinvarianz bildanalytisch erfaßter Blattparameter

	Parameter											
	$\varphi_2$	$\varphi_3$	$\varphi_4$	$\varphi_5$	$\varphi_6$	$\varphi_7$	$\varphi_8$	$\varphi_9$	$\varphi_{10}$	$\varphi_{11}$	$\varphi_{12}$	
$\Delta_{\max}$	0	2	1	53425	0,064	0,024	3,71	0,064	0,007	0,055	40,3	
$\alpha$	-	18	16	27	54	39	23	54	14	26	34	
	Parameter											
	$\varphi_{13}$	$\varphi_{14}$	$\varphi_{15}$	$\varphi_{16}$	$\varphi_{17}$	$\varphi_{18}$	$\varphi_{19}$	$\varphi_{20}$	$\varphi_{21}$	$\varphi_{22}$		
$\Delta_{\max}$	91,1	10359	1,67	0,51	0,074	0,036	0,021	0,043	0,047	0,126		
$\alpha$	56	91	85	34	60	13	84	43	44	11		

$\Delta_{\max}$  : Aufgetretene maximale, absolute Differenz zwischen zwei Aufnahmen eines Blattes

$\alpha$  : Überschreitungswahrscheinlichkeit (t-Test) zur Ablehnung der Nullhypothese :  $\mu_j = 0$  = Erwartungswert der Differenzen für Parameter  $\varphi_j$  (Berechnung siehe DUFNER et al. 1992)

In der ersten Zeile stehen die maximal (in der Regel bei einer Pflanzenart) aufgetretenen absoluten Differenzen. Sie lassen sich durch zufällige Einflüsse wie unterschiedliche Auflage oder Belichtung oder auch durch eine Lageinvarianz der Algorithmen erklären. In der zweiten Zeile ist die Überschreitungswahrscheinlichkeit angegeben, daß sich die für die ausgewählten Blätter berechneten absoluten Differenzen von 0 unterscheiden. Man erkennt, daß zum Teil erhebliche Differenzen auftreten, die allerdings in keinem Fall bei einem  $\alpha$  von 10 % zu einer Ablehnung der Nullhypothese (Erwartungswert der Differenz = 0) führen. Es kann daher von Lageinvarianz der Merkmale ausgegangen werden.

### 6.3 Ergebnisse der computerbildanalytischen Pflanzenbestimmung

#### 6.3.1 Ergebnisse wissensbasierter und statistischer Modellansätze

Abbildung 6.3.1 stellt die Klassifikationsergebnisse des entwickelten zweiwertigen wissensbasierten Modells dar. Die auf der Abszisse aufgetragenen Blattgruppennummern entsprechen den im Anhang verzeichneten Arten. Bis auf die Gruppennummern 41 und 42 (*Aesculus hippocastanum*) repräsentiert jede Gruppennummer eine Pflanzenart. Auf der Ordinate ist die Anzahl möglicher Arten aufgetragen, die nach Einsatz des wissensbasierten Modells vom Rechner als mögliche Klassifikationslösungen erkannt wurden. Die aufgetragenen Bereiche geben die über alle Wiederholungen aufgetretenen Spannweiten wieder. Pflanzenarten mit Varianten, bei denen die richtige Lösung überhaupt nicht innerhalb der vom Rechner angegebenen Lösungsmenge enthalten war, sind mit einem Stern gekennzeichnet. Bei 5 Arten existieren demnach Blätter, bei denen aufgrund von Extremwerten oder Algorithmusfehlern die richtige Lösung fälschlicherweise ausgeschlossen wurde.

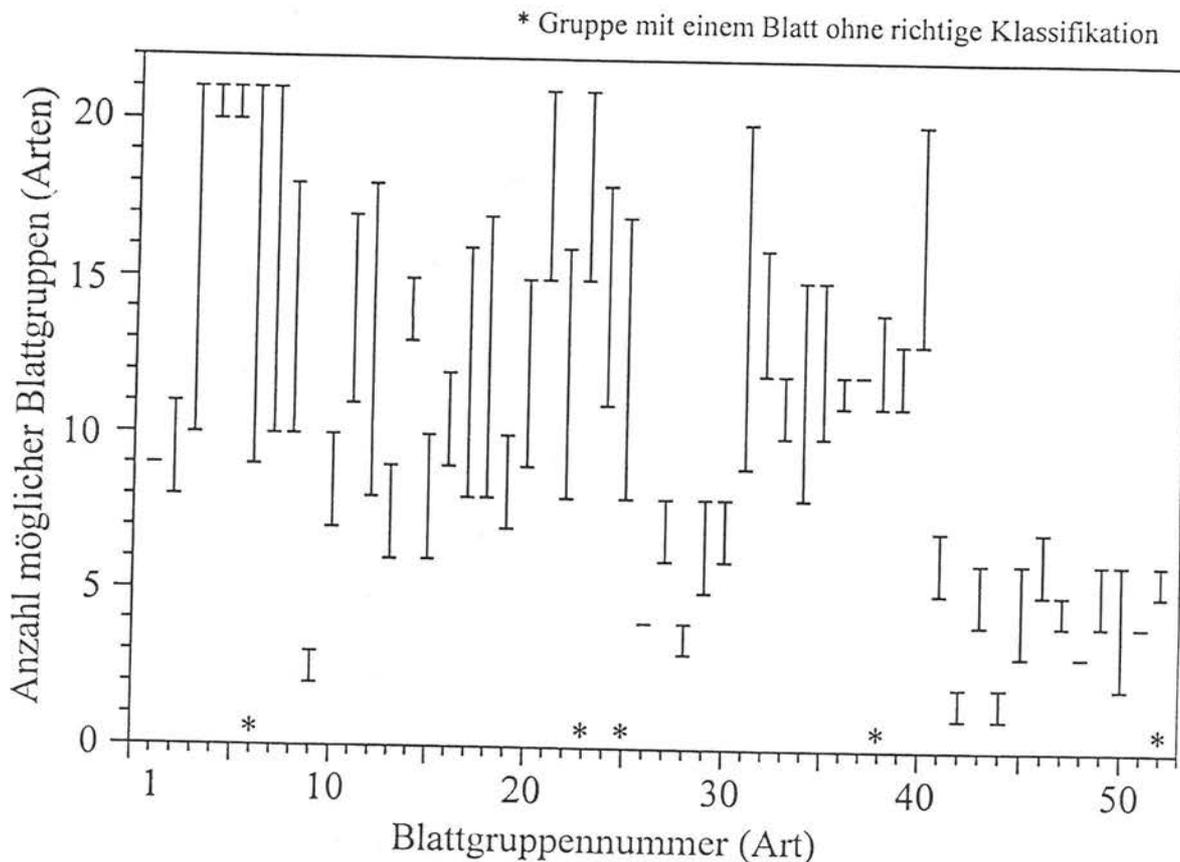


Abbildung 6.3.1: Pflanzenbestimmungsergebnisse auf der Basis des zweiwertigen wissensbasierten Modellansatzes

Abbildung 6.3.1 verdeutlicht, daß mit dem entwickelten wissensbasierten Modell nur eine unzureichende Pflanzenidentifikation möglich ist. Blattgruppen 1 bis 41 beinhalten einfache Blätter. Bei ihnen kann durch den Einsatz des Modells eine Artbestimmung durchgeführt werden, bei der durchschnittlich 10-20 Arten in der Lösungsmenge übrig bleiben. Einzelne Arten (z.B. Nr. 9, 26 oder 28) erzielen zwar etwas bessere Ergebnisse, doch ist auch hier die Klassifikationsgüte mit 2 bis 4 möglichen Pflanzenarten relativ gering. Aus Abbildung 6.3.1 erkennt man, daß bei zusammengesetzten Blättern (ab Blattgruppennummer 42) die Ergebnisse besser ausfallen. Das liegt jedoch daran, daß insgesamt nur 12 Arten mit zusammengesetzten Laubblättern innerhalb der Untersuchungsmenge vorlagen. Da das Bestimmungsmodell sehr gut zwischen einfachen und zusammengesetzten Blättern unterscheiden kann und da der Blattaufbau bei jeder Art als Ausschlußregel verwendet wird, reduziert dieses die Anzahl der generell möglichen Arten auf 12.

Die Abbildungen 6.3.2 bis 6.3.4 geben den Einsatz weiterer Auswertemodelle zur computerbildanalytischen Bestimmung unbekannter Testblätter in Abhängigkeit von der Anzahl der verwendeten Blätter pro Art zur Modellbildung wieder. Die angegebenen Bereiche stellen die Spannweiten innerhalb der Wiederholungen dar. Die Markierungen (Kreise, Dreiecke) kennzeichnen das arithmetische Mittel über alle 10 Wiederholungen. Zur besseren Visualisierung wurde die Abszisse bei Abbildung 6.3.2 und 6.3.3 für unterschiedliche Modellansätze etwas versetzt dargestellt.

Abbildung 6.3.2 zeigt, daß unter Verwendung des Fuzzy-Logik-orientierten Modellansatzes richtige Artenbestimmungen in über 80 % der Fällen möglich sind, wenn mehr als 6 Blätter pro Gruppe zur Bildung der Lerndatensätze verwendet werden. Höchstwerte mit 90,4 % richtiger Identifikation wurden unter Verwendung von 9 Blättern pro Gruppe zur Modellbildung erzielt (Mittelwert 83,6 %). Verwendet man anstatt des Fuzzy-Klassifikators nur arithmetische Gruppenmittel der Parameter innerhalb der Lerndatensätze und klassifiziert die Testblätter anhand des minimalen euklidischen Abstandes zu dem entsprechenden „künstlichen Mittelwertblatt“, ergibt sich ein ähnlicher Verlauf der Klassifikationskurve, jedoch mit um ca. 10 % niedrigeren Klassifikationswerten.

Die Verwendung nichtparametrischer k-neighbor-Klassifikation ist in Abbildung 6.3.3 dargestellt. Abstandsmaß ist die euklidische Distanz: Man erkennt, daß für  $k=1$  (Auswahl des

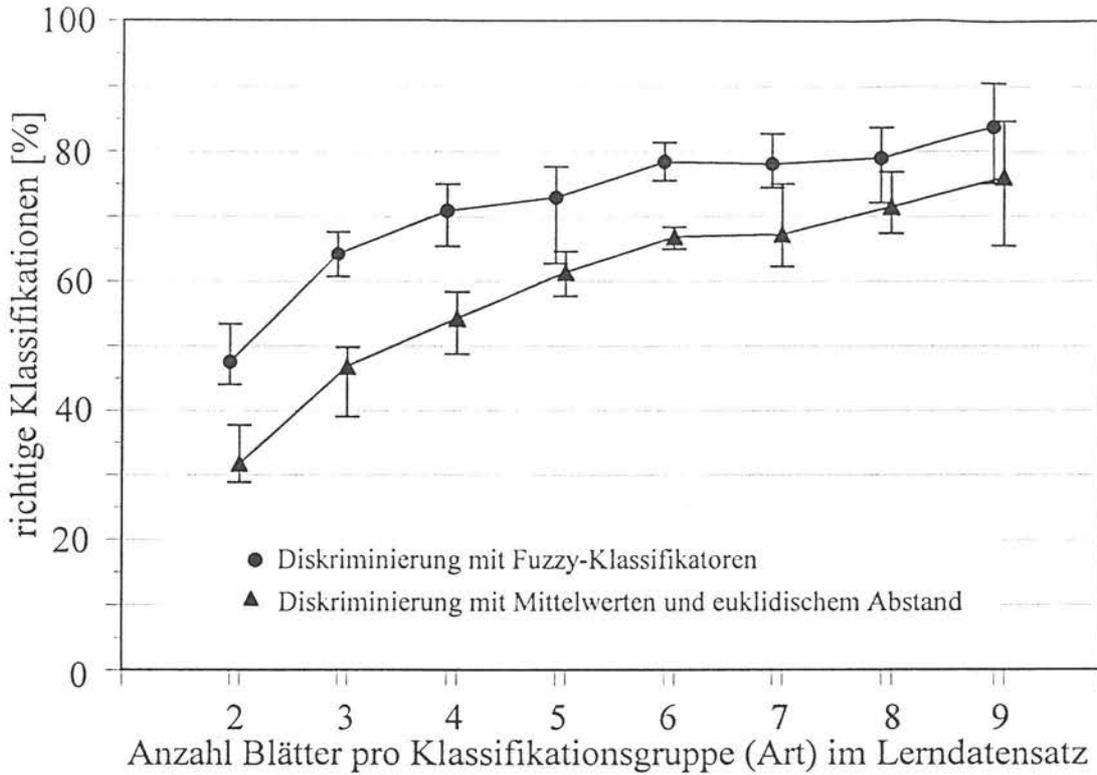


Abbildung 6.3.2: Pflanzenbestimmungsergebnisse bei Einsatz des Fuzzy-logik-orientierten Modellansatzes und eines einfachen Mittelwertansatzes

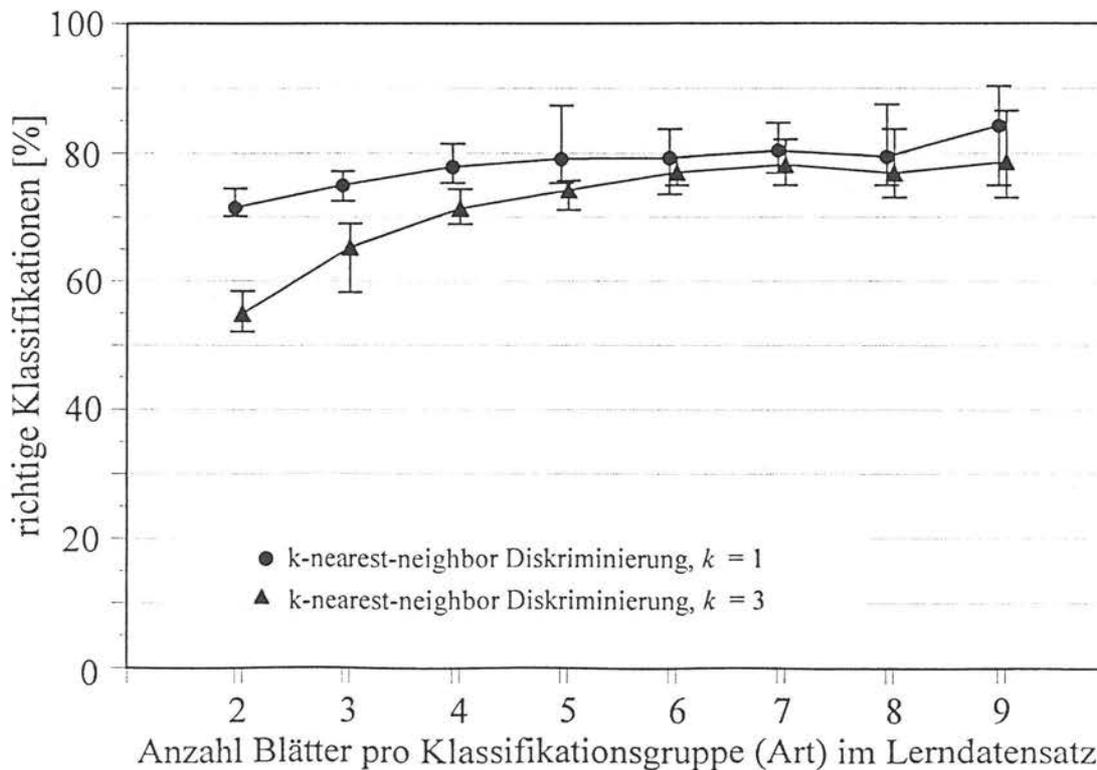


Abbildung 6.3.3: Pflanzenbestimmungsergebnisse bei Verwendung k-nearest-neighbor-Modellansätze

ähnlichsten Blattes) ähnliche Ergebnisse zu erzielen sind wie mit dem Fuzzy-Klassifikator. Der Einfluß der Anzahl der Lernblätter ist allerdings geringer. Beste Ergebnisse werden auch hier mit 9 Lernblättern pro Gruppe erzielt (durchschnittl. 84,2 %, Höchstwert 90,4 %). Für  $k = 3$  (Klassifikation anhand der 3 ähnlichsten Blätter einer Gruppe, bei zwei Lernblättern gilt:  $k = 2$ ) ergeben sich um ca. 5-10 % schlechtere Ergebnisse, die auch noch stark von der Anzahl der Lernblätter abhängen.

Den Einsatz parametrischer Modellansätze unter Verwendung von gepoolten und gruppeninternen Kovarianzmatrizen zeigt Abbildung 6.3.4. Die Verwendung einer linearen Diskriminanzfunktion mit gepoolter Kovarianzmatrix (vgl. Kap. 4.5.2) ergibt bei Verwendung von 9 Lernblättern pro Gruppe richtige Klassifikationen von 84,6 % (Durchschnitt) bzw. 88,4 % (Höchstwert). Obwohl das Maximum etwas geringer als die Höchstwerte bisher vorgestellter Modelle ist, sind die Ergebnisse als sehr gut einzustufen, da sie schon für mehr als 3 Lernblätter pro Gruppe annähernd unabhängig von der verwendeten Anzahl an Lernblättern sind. Deutlich schlechtere Ergebnisse ergibt der Einsatz der quadratischen Diskriminanzfunktion unter Verwendung gruppeninterner Kovarianzmatrizen (vgl. Kap. 4.5.2).

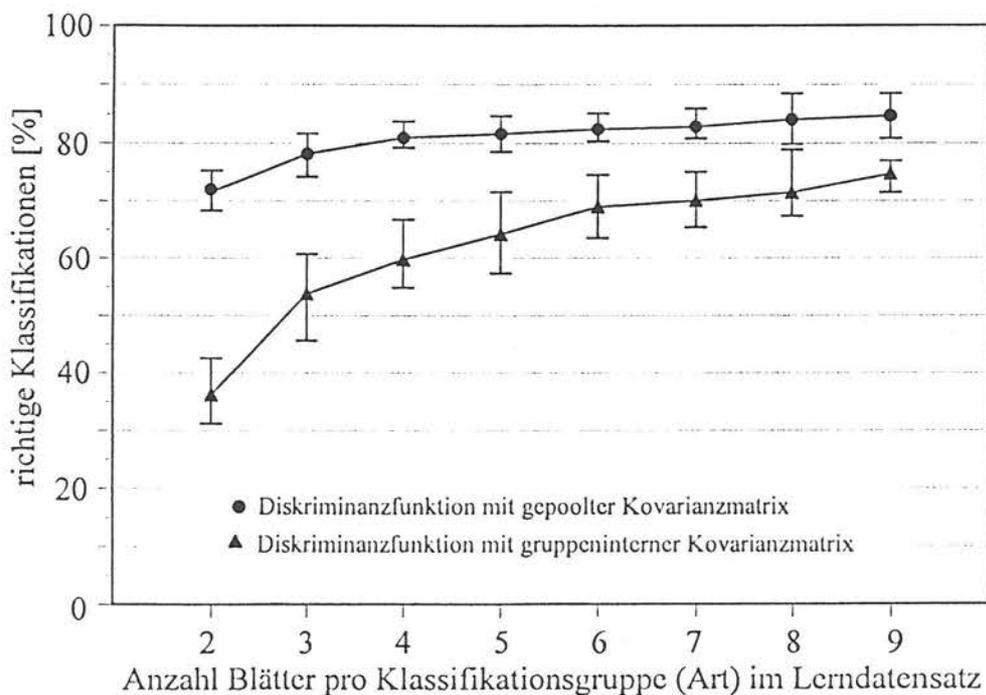


Abbildung 6.3.4: Pflanzenbestimmungsergebnisse bei Einsatz von statistisch orientierten parametrischen Modellansätzen

### 6.3.2 Ergebnisse kombinierter Modellansätze

Bisher dargestellte Ergebnisse verwendeten einen Basismodellansatz, mit dem die Klassifikationen vorgenommen wurden. Im folgenden wird dargestellt, inwieweit mehrere miteinander kombinierte und hintereinander ausgeführte Modellansätze die Ergebnisse der Basismodelle verbessern können.

Tabelle 6.3.1 und 6.3.2 stellen die Veränderung der Klassifikationsgüte der statistisch orientierten Modellansätze dar, wenn eine kanonische Datenverdichtung vorab durchgeführt wird (vgl. Kap. 4.5.2). Tabelle 6.3.1 bezieht sich auf die Verwendung von 9 Lernblättern pro Gruppe, Tabelle 6.3.2 liegen 2 Lernblätter pro Gruppe zugrunde. In der ersten Spalte steht die abkürzende Bezeichnung des Basismodells ( $k = 1$ ,  $k = 3 \Rightarrow k$ -nearest-neighbor-Verfahren, intern  $\Rightarrow$  Verwendung gruppeninterner Kovarianzmatrizen, gepoolt  $\Rightarrow$  Verwendung gepoolter Kovarianzmatrix), in der zweiten Spalte ist das mit dem alleinigen Basismodell erzielbare Klassifikationsergebnis dargestellt. Spalten 3 bis 6 geben die durchschnittliche Veränderung der Werte aus Spalte 2 bei Einsatz von unterschiedlicher Datenverdichtung wieder.

Tab. 6.3.1: Durchschnittliche Pflanzenbestimmungsergebnisse unter Verwendung der kanonischen Vorverdichtung und von 9 Blättern pro Gruppe zur Modellbildung

Basismodell		Veränderung der Klassifikationsgüte bei Verwendung von $n$ kanonischen Variablen [%]			
Bezeichnung	richtige Klassifikation [%]	$n = 5$	$n = 10$	$n = 15$	$n = 20$
$k = 1$	84	-10	0	+1	+1
$k = 3$	79	-8	+1	+5	+3
intern	75	+2	-53	-1	-1
gepoolt	85	-12	-2	0	0

Es wird deutlich, daß beste Ergebnisse unter Verwendung von mehr als 15 kanonischen Variablen erzielt werden. Eine stärkere Vorverdichtung führt zu einem zu großen Informationsverlust und zur Verschlechterung der Ergebnisse. Bei Verwendung von 9 Lernblättern pro Gruppe zur Modellbildung können die Basismodellansätze mit guter Klassifikationsgüte ( $k=1$ , gepoolt) durchschnittlich nicht bzw. nur unwesentlich verbessert werden, während bei „schlechteren“ Modellansätzen deutliche Ergebnisverbesserungen zu erzielen sind. Diese Aussage gilt auch für die Maximalwerte (in den Tabellen nicht dargestellt). In keinem Fall wurde das beste Ergebnis der alleinigen Basismodelle durch den Einsatz der kanonischen Vorverdichtung übertroffen. Bemerkenswert ist, daß es bei der kanonischen Datenvorverdichtung zu erheblichen Schwankungen innerhalb der Ergebnisse in Abhängigkeit von der verwendeten Variablenanzahl kommt (vgl. z.B. Zeile 3: -53 % zu -1 % bzw. +1 %). Wie aus Tabelle 6.3.2 ersichtlich, gelten die bisher gemachten Aussagen auch bei Verwendung einer geringen Anzahl an Lernblättern. Die Verbesserung der „schlechten“ Modellansätze ( $k=3$ , intern) ist allerdings deutlicher.

Tabelle 6.3.2: Durchschnittliche Pflanzenbestimmungsergebnisse unter Verwendung kanonischer Vorverdichtung und bei 2 Blättern pro Gruppe zur Modellbildung

Basismodell		Veränderung der Klassifikationsgüte bei Verwendung von $n$ kanonischen Variablen [%]			
Bezeichnung	richtige Klassifikation [%]	$n = 5$	$n = 10$	$n = 15$	$n = 20$
$k = 1$	72	-18	-4	-1	-1
$k = 3$	55	-8	+7	+9	+9
intern	36	-2	+8	+7	-5
gepoolt	72	-16	-3	-1	0

Abbildung 6.3.5 stellt Klassifikationsergebnisse dar, wenn die Artbestimmung zuerst mit dem wissensbasierten System durchgeführt wird, um anschließend die mögliche Lösungsmenge mit einem statistischen, Fuzzy-logik-orientierten oder auf Gruppenmittelwerten aufbauenden Modellansatz zu verdichten. <sup>wo sind 6.3.3 u. 6.3.4?</sup> Abgebildet sind die arithmetischen Mittel und die Spannweiten der 10 Wiederholungen. Um die Vergleichbarkeit zu gewährleisten, wurden

sowohl beim Einsatz der Basismodelle als auch bei der Blattbestimmung mit dem kombinierten Ansatz jeweils gleiche Lerndatensätze (9 Lernblätter pro Gruppe) und Testblätter benutzt. Die Bezeichnung der Basismodelle ist analog der Angaben in Tabelle 6.3.1 zu verwenden. Die Abkürzungen 'fuzzy' und 'mittel' kennzeichnen die Basismodelle aus Abbildung 6.3.2. Der Übersichtlichkeit halber wurden die Ergebnisse der Basismodelle und der kombinierten Verfahren etwas versetzt zueinander dargestellt.

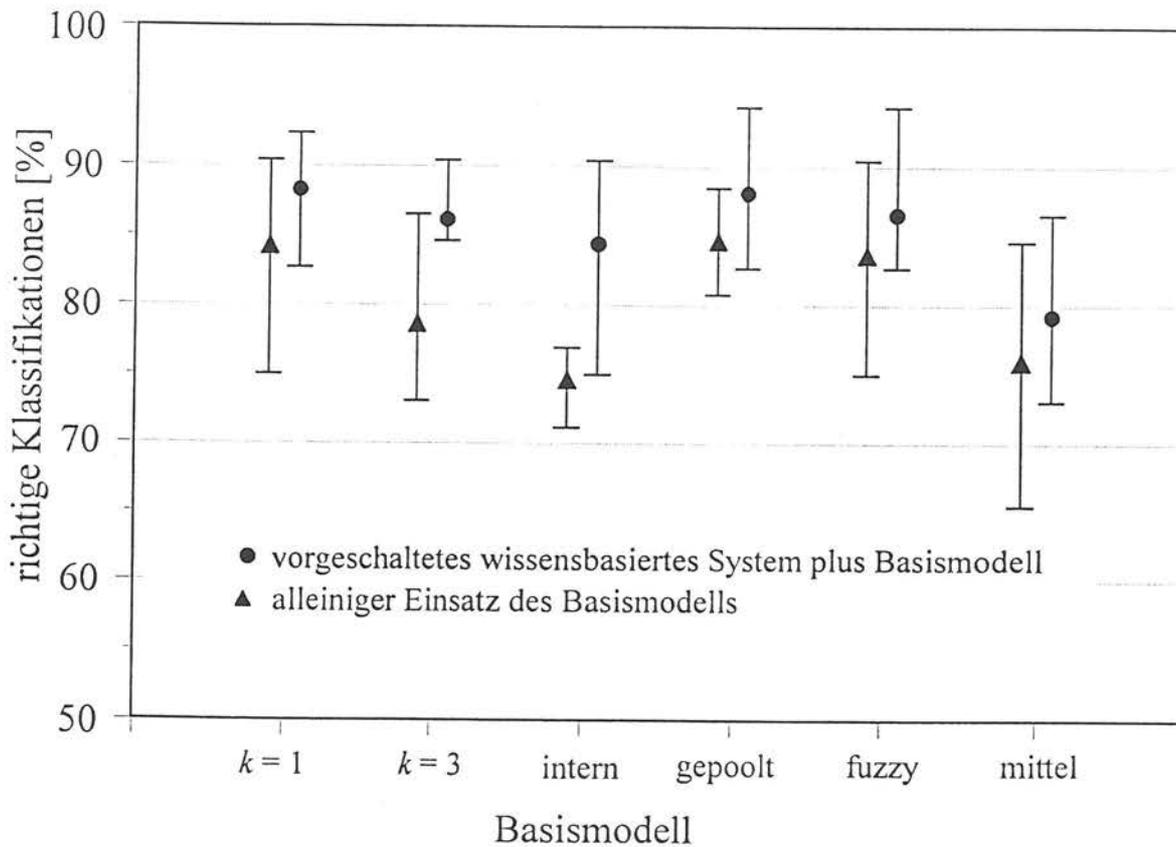


Abbildung 6.3.5: Pflanzenbestimmungsergebnisse unter Verwendung von Basismodellen und kombinierten Modellansätzen (Lerndatensatz mit 9 Blättern pro Gruppe)

Man erkennt, daß die Eingrenzung der möglichen Lösungsmenge mit einem Entscheidungsregelsystem vor der weiteren Datenverdichtung zu Klassifikationsverbesserungen bis zu 10 % führt. Selbst gute Klassifikationsergebnisse (gepoolt, fuzzy,  $k = 1$ ) lassen sich mit der Kombination mit dem wissensbasierten System noch um rund 4 % auf Durchschnittswerte von 87 % (fuzzy) und 88 % (gepoolt,  $k = 1$ ) verbessern. Insbesondere wird deutlich, daß selbst „schlechte“ Modellansätze auf hohe Klassifikationswerte von über 85 % kommen.

Die Ausnahme bildet hier der Mittelwertansatz, bei dem offenbar durch die Mittelwertbildung zuviel spezielle Blatinformation verloren geht.

Betrachtet man die Streuung der einzelnen Ergebnisse über die Wiederholungen, so sieht man, daß durch die Eingrenzung der Lösungsmenge verständlicherweise die Streuung der parameterfreien statistischen Modellansätze ( $k = 1$ ,  $k = 3$ ) geringer wird. Die Abhängigkeit der Klassifikationsergebnisse hängt nicht mehr so stark von der zufälligen Auswahl der Lern- und Testblätter ab. Im Gegensatz dazu steigt, bedingt durch die geringere Anzahl an Lerndaten, die Streuung der parametrischen Ansätze (intern, gepoolt) an. Bei den Fuzzylogik-orientierten und Mittelwert-orientierten Modellen wirkt sich die Vorschaltung des wissensbasierten Systems nur unwesentlich auf die Streuung aus.

Eine nähere Analyse der beiden Modellansätze, die in Einzelfällen die besten Klassifikationsergebnisse mit 94 % erzielten, ergab, daß die entstandenen Fehlbestimmungen entweder durch ein „Verwecheln“ ähnlicher Arten entstanden oder daß das wissensbasierte System die richtige Lösung ausgeschlossen hatte.

### 6.3.3 Ergebnisse künstlicher neuronaler Netzwerke

Bisher vorgestellte Modellergebnisse basierten auf inhaltlich-statistischen Zusammenhängen des Merkmalraumes. Im folgenden wird diesen Ansätzen ein vollständig black-box-orientierter Modellansatz gegenübergestellt. Zur Bildung der Black-Box-Modelle wurde der in Kap. 5.4.4 beschriebene Neuronale-Netzwerk-Ansatz mit den entsprechenden Variationen (Lernzyklen) ausgewählt. Abbildung 6.3.6 zeigt die Klassifikationsergebnisse dieser Ansätze. Zur besseren Visualisierung ist auch hier die Abszisse für die einzelnen Variationen versetzt dargestellt. Die vier Abschnitte entsprechen quasi dem Lernverlauf des Netzes.

Beste Ergebnisse wurden nach Abbildung 6.3.6 mit 2000 Lernzyklen (87 % Maximalwert und 77 % Durchschnittswert) und bei kleineren Lerndatensätzen mit 500 Lernzyklen erzielt. Eine Erhöhung der Lernzyklen auf 5000 führte in allen Fällen wieder zu einer Abnahme der richtigen Klassifikationen, da das Netz offensichtlich zu speziell auf die Lerndatensätze ausgerichtet wurde. Weiter fällt auf, daß bei geringer Lerndatensatzgröße eine erhöhte Anzahl

an Lernzyklen notwendig war, um Ergebnisse um bzw. über 60 % zu erzielen. Ferner scheinen besonders die Modelle mit einer hohen Anzahl an Lerndatensätzen eine große Streuung der Ergebnisse hervorzurufen. Dieser Effekt kann durch den Lernvorgang und die Netztopologie bedingt sein. Denkbar ist aber auch, daß die bei größeren Lerndatensätzen kleiner werdenden Testdatensätze die Ursache darstellen (da die Angaben in Prozent erfolgen).

Ein Vergleich mit den bisher vorgestellten Ergebnisse zeigt, daß mit dem neuronalen Netzwerk nicht die guten Klassifikationsergebnisse der anderen Ansätze erreicht wurden. Sie liegen um ca. 7 % niedriger als bei den „besten“ Basismodellen und um ca. 10 % niedriger als bei den „besten“ kombinierten Verfahren.

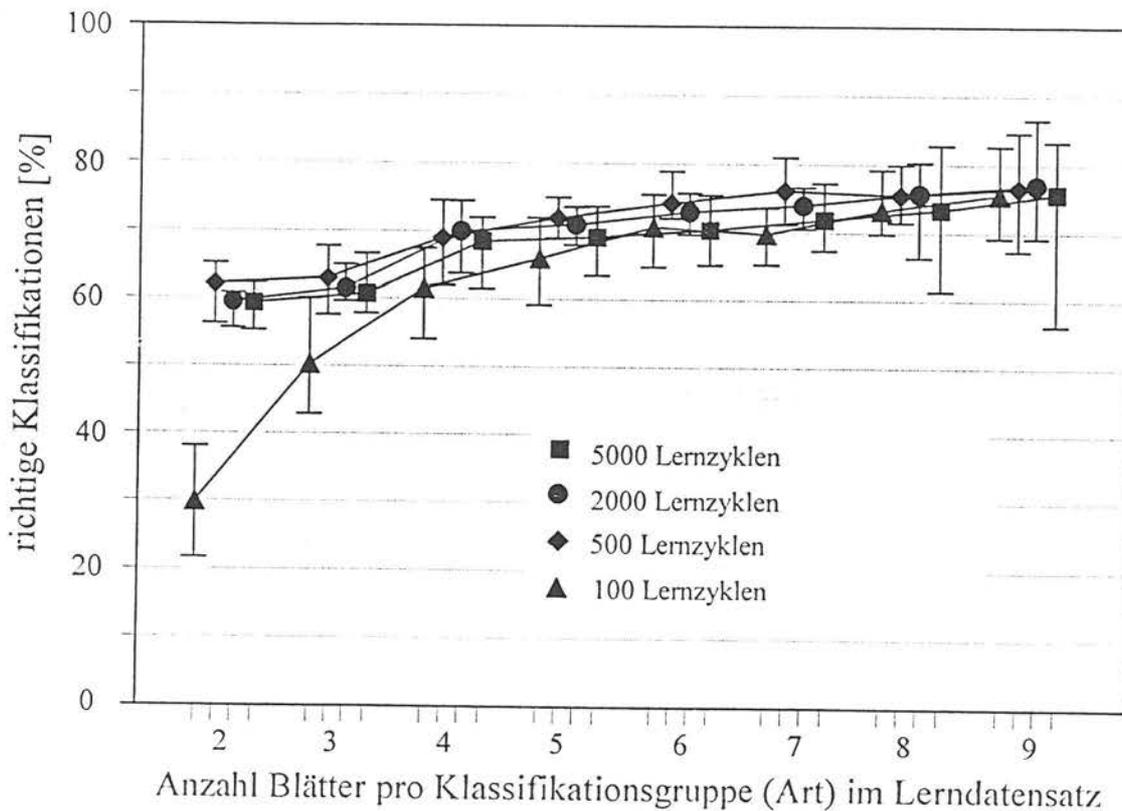


Abbildung 6.3.6: Klassifikationsergebnisse neuronaler Netzwerke

## 7. Diskussion und Schlußfolgerungen

### 7.1 Diskussion der Methoden zur Bildbearbeitung und Merkmalsextraktion

#### 7.1.1 Grundlegende methodische Ansätze zur Bildbearbeitung

Wesentliches Kriterium bei der computerbildanalytischen Pflanzenbestimmung ist die Extraktion und Parametrisierung der Unterscheidungsmerkmale. Der gesamte Pflanzenbestimmungsprozeß baut auf den methodischen und inhaltlichen Ansätzen der Merkmalbestimmung auf. Bisherige Anwendungen verwendeten standardmäßig neben der Binarisierung mit Schwellenwertfiltern pixelorientierte Flächen- oder Umrißparameter zur Beschreibung von Form und Ausprägung pflanzlicher Objekte (siehe Arbeiten in Kapitel 2). Die Formparameter wurden auf die gesamte Pflanze bzw. auf zu analysierende Pflanzenteile angewendet oder waren theoretisch ausgerichtet. YONEKAWA et al. (1996) befassen sich zum Beispiel in speziellen Untersuchungen mit dem Einsatz von Blattformparametern zur dendrologischen Pflanzenbestimmung (nach ihrer Ansicht können theoretisch 1280 Blatt-typen mit gängigen Formparametern klassifiziert werden). Sie gehen bei den Untersuchungen aber von Blättern ohne Stiel, ohne Blatzzählung und ohne botanische Variabilität etc. aus. Eine vom inhaltlichen Aspekt notwendige Separierung einzelner Bildbestandteile erfolgte nicht bzw. nur in begrenztem Umfang (z.B. bei SIMONTON und PEASE 1993, RIGNEY und KRANZLER 1988, FRANZ et al. 1995, HUMPHRIES und SIMONTON 1993, SHIMIZU und HEINS 1995). Andere methodische Ansätze wie der Einsatz von vollständigen Bildtransformationen zur Merkmalgewinnung mit der Hough-Transformation, Fouriertransformation oder mit Co-occurrence-Matrizen (siehe Arbeiten aus Kapitel 2) sind ebenso nicht inhaltlich (botanisch) begründet und stellen damit formell ausgerichtete Ansätze dar.

Aus diesen Gründen wurde in der vorliegenden Arbeit bewußt versucht, andere methodische Ansätze zu nutzen, um eine inhaltlich-botanisch ausgerichtete Bildverarbeitung zu realisieren. Hierzu wurde die mathematische Morphologie verwendet. Dieser keineswegs neue bildanalytische Ansatz ist nach MCDONALD und CHEN (1990) geeignet, auch bei sehr variablen pflanzenbaulichen Objekten inhaltliche Strukturen herauszuarbeiten. Objekte werden so verformt, daß wesentliche Merkmale erhalten bleiben und anschließend mit Formparametern beschrieben werden können. HARALICK et al. (1987) bezeichnen die morphologische Filterung als eine Bildbearbeitung, die in unmittelbarem Zusammenhang zu Formeigenschaften der zu bearbeitenden Objekte steht. Abgesehen von einer Arbeit zur Trennung von

Getreidekörnern (SHATADAL et al. 1995) benutzte erstaunlicherweise bisher keine Untersuchung im Bereich des Pflanzenbaues den Einsatz von morphologischen Operatoren als zentralen Ansatz.

Die in Kapitel 5.3 beschriebenen Algorithmen und deren Ergebnisse zeigen, daß es möglich ist, eine botanisch orientierte Merkmalextraktion mit morphologischen Operatoren durchzuführen. Da die entwickelten Bildverarbeitungsalgorithmen im wesentlichen nur auf den Operationen Erosion, Dilation, Schnitt- und Vereinigungsmengenbestimmung aufbauen, lassen sie sich auch auf andere Systeme hard- und softwareorientiert übertragen. Durch die Verwendung von nur zwei Verschiebungsmasken (4-er Nachbarschaft mit 5 Pixeln und 8-er Nachbarschaft mit 9 Pixeln) wurde ein Maximum an Vereinfachung und Vereinheitlichung erzielt. Eine Steigerung der Effizienz morphologischer Operatoren konnte durch die zusätzliche Verwendung von geometrisch orientierten Zeichenverfahren erzielt werden.

Die von MCDONALD und CHEN (1990) aufgeführte Robustheit morphologischer Operatoren konnte hingegen nicht bestätigt werden. Kleinere Unterschiede innerhalb der Ausgangsbilder hatten zum Teil große Auswirkungen auf die Merkmalextraktion. Besonders deutlich wurde dieser Sachverhalt bei der Skelettierung der Objekte, wo durch Pixelunterschiede innerhalb der Binärbilder völlig andere Skelettformen entstehen können, die auch noch vom gewählten Skelettierungsalgorithmus und eventuell von der Lageorientierung abhängen (vgl. hierzu auch JANG und CHIN 1990 oder RATH 1996b).

Schließlich bleibt festzuhalten, daß zukünftige Arbeiten auf dem Gebiet der Pflanzenbestimmung die mathematische Morphologie als Grundkonzept innerhalb der Bildverarbeitung und der inhaltlich orientierten Merkmalextraktion nutzen sollten. Zu berücksichtigen ist dabei, daß ein erhöhter Zeitbedarf zur Modellentwicklung benötigt wird, da die an Einzelobjekten entwickelten Algorithmen sehr sorgfältig auf ihre Allgemeingültigkeit hin zu überprüfen sind. Im vorliegenden Fall wurde schätzungsweise über 60 % des gesamten Modellbildungsaufwandes allein für die Entwicklung, Überprüfung und Optimierung der Merkmalextraktionsalgorithmen verwendet. Zukünftige Entwicklungen können jedoch auf die in Kapitel 5 beschriebenen Algorithmen aufbauen und diese verwenden. Da die mathematische Morphologie auch für Grauwert- und Farbbildinterpretationen (siehe HARALICK et al. 1987) und sogar auch für 3-D-Merkmalextraktion (siehe STERNBERG 1986) und hard-

ware-orientiert (vgl. JUNGSMANN 1984) genutzt werden kann, steht dem Einsatz auch bei Verwendung einer anderen Aufnahmetechnik als der hier vorliegenden Schwarz-Weiß-Scanner-Technik nichts im Wege. Im Einzelfall ist allerdings zu klären, inwiefern Schwellenwertfilterung eine inhaltlich orientierte Objektdifferenzierung oder -unterteilung ermöglichen (z.B. wäre dies im vorliegenden Fall möglich gewesen, wenn die Blattstiele immer einen anderen Grauwert als das übrige Blatt aufgewiesen hätten). Der Entwicklungsaufwand gegenüber dem Einsatz morphologischer Operatoren ließe sich hiermit sicherlich verringern.

### 7.1.2 Spezielle Ansätze zur Merkmalextraktion und -parametrisierung

Ansätze zur Parametrisierung von Bildmerkmalen lassen sich analog zu den verschiedenen Verfahren der Bildcodierung und Grafikedarstellung (siehe hierzu Kapitel 4.1) einteilen. Im einzelnen können folgende Parametrisierungsansätze voneinander unterschieden werden:

- I: Flächenanalyse: Nutzung pixelflächenorientierter, geometrischer Flächenmerkmale
- II: Konturanalyse: Nutzung von Merkmalen des Kettencodes bzw. des Objektrandes
- III: Texturanalyse: Parametrisierung anhand von Texturmerkmalen
- IV: Farbanalyse: Ausnutzung von Farbunterschieden unter Verwendung von Farbräumen
- V: Analyse mit Vergleichsobjekten oder Modellen

ad I: Zur Parametrisierung der Blattmerkmale wurden dimensionslose, in Vorversuchen ausgewählte Flächenkennzahlen wie Konvexität, Kompaktheit oder Rundheit verwendet. Der Einsatz dieser Merkmalparametrisierung ist durch die Aufgabenstellung nahezu zwingend gegeben und stellt von der methodischen Seite keine neue Entwicklung dar, da er in Bildverarbeitungsanwendungen und -untersuchungen häufig verwendet wird (vgl. hierzu auch YONEKAWA et al. 1996). Einige Softwaretools ermöglichen bereits einen nahezu standardisierten Einsatz von flächenorientierten Merkmalparametern. Um den besonderen Eigenschaften der Untersuchungsobjekte (Blätter) gerecht zu werden, wurden zusätzlich weitere dimensionslose Flächenparameter wie Eckigkeit, Elliptizität, Länge zu Breite etc. entwickelt. Sie lassen sich auf die vorhandenen Grundparameter zurückführen und sind in einigen Fällen zur besseren Wirksamkeit an der Ausrichtung der Blattachse orientiert worden. Durch diese Orientierung erhöht sich die inhaltliche Aussagekraft der Parameter. Anderer-

seits resultiert daraus bei falscher Achsenbestimmung eine Fehlparametrisierung, die eventuell zur Fehlklassifikation führt. Ähnliche Aussagen gelten auch für die entwickelten dimensionsbehafteten Flächenparameter wie Stiellänge, Blattfläche, Blattanzahl etc.. Da auch hier morphologische Operationen entscheidend in die Parametrisierung eingreifen, erhöht sich das Risiko einer Fehlparametrisierung, gleichzeitig erhöht sich aber die botanische Interpretierbarkeit der erfaßten Merkmale.

ad II: Zur Parametrisierung der Blattrandeigenschaften wurde ein sehr einfach strukturierter Ansatz entwickelt, der sich von den in anderen Anwendungen vorgeschlagenen Verfahren insofern unterscheidet, als daß er den Kettencode unmittelbar interpretiert. Durch den vereinfachten Ansatz konnten Parameter mit akzeptabler Trenneigenschaft für bestimmte Blattrandgrundstrukturen erzielt werden, während eine Klassifikation nach Blattrandfeinstrukturen nur begrenzt mit kombinatorischen Auswerteverfahren möglich war. Andere methodische Ansätze könnten hier eventuell eine Verbesserung erbringen (siehe z.B. KOPLOWITZ und PLANTE 1995, FRANZ et al. 1995, LIU und SRINATH 1990, SÖKEFELD et al. 1996) und eine noch bessere Unterscheidung von Feinstrukturen ermöglichen. Die Ergebnisse von SÖKEFELD et al. (1996) deuten allerdings darauf hin, daß auch hier Grenzen bestehen. Darüber hinaus sind nicht alle Verfahren voll automatisierbar. Sie benötigen vielmehr manuelle Zusatzinformationen über die Objekte (FRANZ et al. 1995) oder spezielle Schwellenwerte zur Unterscheidung zwischen Ecken, die durch Konturunschärfe oder durch die Objektgeometrie bedingt sind (LIU und SRINATH 1990). Ferner ist nicht garantiert, daß bei anderen Verfahren immer Größen- und Lagevarianz existiert. Konkrete Untersuchungen in einer ähnlichen zu der hier behandelten Aufgabenstellung liegen nicht vor.

ad III: Aus dem vorliegenden Pflanzenmaterial konnten keine direkt nutzbaren Texturmerkmale gewonnen werden, die eine artspezifische botanische Interpretation ermöglichen. Abbildung 5.2.2 zeigt, daß mit Hilfe mehrerer hintereinandergeschalteter Grauwertfilteroperationen zum Teil Blattneraturen als botanische Merkmale extrahiert werden können. Die mögliche Parametrisierung dieser Merkmale konnte begrenzt mit dem in Kap. 5.2 beschriebenen Box-counting-Verfahren durchgeführt werden. Es zeigten sich allerdings erhebliche Probleme bei der Realisierung dieses Ansatzes. Obwohl das Adernsystem der Laubgehölze theoretisch mit der fraktalen Geometrie parametrisiert werden kann (siehe KULL und HERBIG 1995), muß in Frage gestellt werden, ob eine praktische Durchführung

dieses Verfahrens erreichbar ist. Andere Untersuchungen bezweifeln generell, ob der fraktale Ansatz geeignet ist, in der Realität natürliche Strukturen zu parametrisieren (siehe hierzu HUANG et al. 1994, CRITTEN 1996).

Auf die Verwendung der Blattnervatur als Bestimmungsmerkmal wurde daher aus folgenden Gründen verzichtet:

- Bei vielen Blättern konnte die Blattnervatur aufgrund der Überlagerung durch anderer Blattbestandteile nicht oder nur unvollständig separiert werden. Die anschließend eingesetzte Parametrisierung führte zu willkürlichen Ergebnissen.
- Falls Blattnervaturen extrahierbar waren, ergab die Parametrisierung eine sehr große Variabilität der Merkmale innerhalb der Gruppen.
- Zufällige Farb- und Strukturunterschiede waren nicht artspezifisch, wurden als Nervaturen interpretiert und führten zu Fehlinterpretationen.

Versuche, die fehlenden Grauwertunterschiede mit Hilfe von Linienverfolgungsalgorithmen, Hough-Transformationen oder Polygonenschätzungen auszugleichen, waren nicht erfolgreich. Abschließend muß festgestellt werden, daß eine Nutzung der Blattinnenflächen zur Artenunterscheidung mit der eingesetzten Technik und bei der vorliegenden Blatt- und Bildbeschaffenheit nicht möglich ist. Weiterführende und einsetzbare Methoden aus der Literatur sind nicht bekannt, bzw. nicht auf das vorliegende Problem übertragbar (z.B. Texturanalyse von SHEARER und HOLMES 1990), so daß diese Frage als ungelöstes Problem bestehen bleibt.

ad IV: Farbklassifikationen werden im Bereich des Pflanzenbaues zunehmend eingesetzt. Besonders zur schnellen und sicheren Unterscheidung von Pflanzen und Boden sind sogenannte spektrale Signaturen nutzbar (vgl. z.B. MASSEN 1996 oder BURMEISTER 1996). Eine artspezifische Farbauswertung ist allerdings schwierig, da umweltbedingte, ernährungsbedingte, lokal auftretende oder auch zufällige Farbunterschiede die artspezifische Färbung überlagern. Hinzu kommt, daß in botanischen Bestimmungsschlüsseln farbspezifische Merkmale nur von untergeordneter Rolle sind. Innerhalb der vorliegenden Aufgabenstellung wurde daher von Anfang an auf die Farbinterpretation der Blätter verzichtet. In zukünftigen Entwicklungen könnte sie jedoch zu einer Erweiterung der bisherigen Lösungsansätze zumindest in Teilbereichen führen.

ad V: In technisch orientierten Bereichen (z.B. KFZ-Identifikation, Qualitätskontrolle) werden computerbildanalytische Fragestellungen durch die Differenzbildung zwischen Ausgangsbild und Prüfmuster realisiert. Da bei pflanzenbaulichen Identifikationsproblemen keine standardisierten Prüf- oder Beispielmuster vorliegen und zudem die zu untersuchenden Objekte zum Teil sehr variabel sind, ist ein direkter Musterbild-Vergleich nicht möglich. Hinzu kommt, daß Größenunterschiede, leichte Formveränderungen und unterschiedliche Aufnahmerichtungen vorhanden sind, die eine mustergestützte Bildverarbeitung deutlich erschweren. Eine Lösung dieses Problems könnte im Einsatz von flexiblen Mustern (Modellen) liegen, wie sie forschungsorientiert in anderen Bereichen, aber auch speziell schon zur Blattanalyse angewandt und untersucht wurden (siehe BALDOCK 1992, MOLLER NIELSEN et al. 1995). Inwieweit sie verbesserte Klassifikationsergebnisse liefern, bleibt abzuwarten. Bisherige Anwendungen deuten darauf hin, daß die bei der merkmalgestützten Bildverarbeitung entstehenden Probleme und Unwägbarkeiten der Merkmalextraktion bei modellbasierten Ansätzen nur auf die Ebene der Parametrisierung der Modelle verschoben werden. Weitere Forschungsarbeiten müßten hier Klärung bringen.

### **7.1.3 Auswahl der Blattmerkmale**

Ziel der Bildverarbeitung innerhalb von Klassifikationsaufgaben ist es, wichtige Entscheidungsmerkmale aus einem Bild herauszufiltern, um sie anschließend numerisch zu parametrisieren. Die Entscheidung, welche Merkmale in welcher Form erfaßt werden sollen, hängt allein vom Modellentwickler ab und ergibt sich nur in den wenigsten Fällen zwingend aus der Aufgabenstellung. Häufig ist die Auswahl der verwendeten Bildmerkmale das entscheidende Modellierungskriterium dafür, ob eine bildanalytische Klassifikation erfolgreich ist oder nicht. Da im vorliegenden Fall eine botanisch orientierte Pflanzenbestimmung durchgeführt werden sollte, wurden die Merkmale und Parameter allein aus inhaltlichen (botanischen) Gesichtspunkten ausgewählt. Allgemein gelten folgende Anforderungen:

1. Die ausgewählten Merkmale müssen inhaltlich relevant sein und wesentliche Klassifikationskennzeichen darstellen.

2. Die ausgewählten Merkmale sollten statistisch „günstige“ Eigenschaften aufweisen (hohe F-Werte, Lage- und Größeninvarianz, geringe Korrelationen und Variationen)
3. Die ausgewählten Merkmale sollten möglichst wenig Scheinkorrelationen zu nicht richtigen Pflanzenarten erzeugen.
4. Die Algorithmen und Verfahren zur Merkmalextraktion müssen auf andere Fälle übertragbar sein und sollten mit geringer Fehlerquote ausgeführt werden können.
5. Die Berechnung der ausgewählten Parameter muß mit angemessenen Rechnerkapazitäten und in angemessener Rechenzeit verwirklicht werden können.

Eine Überprüfung der Forderungen zeigt, daß aufgrund der ermittelten F-Werte alle ausgewählten Parameter zur Pflanzendifferenzierung verwendet werden können. Neben ungünstigen statistischen Eigenschaften einzelner Parameter fällt allgemein die hohe Korrelation der Werte untereinander auf. DEICHSEL und TRAMPISCH (1985) schlagen vor, erst bei einem Korrelationskoeffizient von  $> 0,9$  Parameter aus den Auswertungen herauszunehmen. Da ferner die hohen Korrelationen Bereiche betreffen, in denen die Parameter aufgrund des inhaltlichen Zusammenhanges eng miteinander verknüpft sind, wurde dem Kriterium Korrelation nicht weiter Rechnung getragen.

Im Bereich der Blattstiel- und Blattachsenerkennung wurden Merkmale extrahiert, bei denen das Kriterium 4 zum Teil nicht erfüllt wurde, da die Merkmalerfassung trotz Optimierung fehlerbehaftet war. Durch die große Auswirkung dieser Parameter auf den gesamten Bildverarbeitungsprozeß stellte die Fehlerrate von unter 5 % zum Teil ein Problem für den gesamten Bildverarbeitungsprozeß dar. Da eine Verbesserung der Merkmalextraktionsalgorithmen aufgrund der zahlreichen vorgenommenen Veränderungen nicht realistisch erscheint, muß die Fehlerrate als unabwendbar eingeschätzt werden. In diesem Zusammenhang sei erwähnt, daß jede algorithmische Veränderung in zentralen Merkmalbereichen einen enormen Arbeitsaufwand darstellt, da sowohl die Veränderung des jeweiligen Parameters als auch etwaige Veränderungen darauf aufbauender Parameter für alle Blätter visuell überprüft und analysiert werden müssen. Im konkreten Fall der Blattstielerkennung ist bei einer Komplettüberprüfung von 520 Blättern von einer Zeitdauer von ca. 40 Stunden auszugehen.

Die Bestimmung der Blattanzahl weist ebenfalls in einigen Fällen Fehler auf, was aber für den Bestimmungsprozeß nicht von so großer Bedeutung ist wie bei der Blattstielerkennung. Kritischer in diesem Bereich sind die langen Rechenzeiten zur Bestimmung der Parameter (zwischen 2 und 5 Minuten). Algorithmenverbesserungen und größere Rechnerkapazitäten könnten dieses Problem wahrscheinlich beheben.

Eine Fehlerquote im Bereich der Blattlappenbestimmung konnte aufgrund des fehlenden Vergleichsmaßstabes nicht angegeben werden. Auf jeden Fall hat der Parameter einen geringen direkt botanisch interpretierbaren Wert und führt in den Fällen, in denen sowohl gelappt als auch ungelappte Blätter innerhalb einer Art auftreten, wahrscheinlich zu Scheinzusammenhängen. Aufgrund seiner statistischen Verwendbarkeit wurde der Blattlappenparameter trotzdem innerhalb der Wertemenge belassen.

Die drei Blattrandparameter weisen ebenso wie die Blattlappigkeit eine relativ geringe botanisch interpretierbare Aussagekraft (Punkt 1) auf. Dazu kommen noch die ungünstigen Ergebnisse der statistischen Analyse. Aufgrund ihrer großen Bedeutung innerhalb der Bestimmungsschlüssel und aufgrund ihrer besseren Aussagekraft bei kombiniertem Einsatz mehrerer Parameter wurden sie trotzdem zur Klassifikation verwendet. Zukünftige Arbeiten sollten aber weitere Ansätze und Verfahren in diesem Bereich überprüfen (s.o.).

## **7.2 Diskussion der Methoden zur Merkmalauswertung und Dateninterpretation**

Zur Datenauswertung wurden verschiedene Modellansätze verwendet, deren Beurteilung anhand vier wichtiger Anforderungen, Kriterien bzw. Fragestellungen erfolgt: Erstens ist zu überprüfen, welche Ansätze eine möglichst hohe Klassifikationsgüte mit möglichst geringer Schwankung bei der Verwendung unterschiedlicher Datensätze haben. Da im Normalfall Bestimmungsmodelle sukzessive aufgebaut und erweitert werden, ist es zweitens von Bedeutung, inwiefern die eingesetzten Modelle erweiterbar und auf neue Datensätze anwendbar sind. Drittens ist zu überprüfen, ob und in welchem Maße die optimale Modellstruktur durch den gewählten Ansatz vorgegeben ist. Einige Modellansätze sind sehr variabel gestaltbar und lassen dem Modellentwickler großen Spielraum bei der Strukturierung, andere Ansätze sind starr vorgegeben. Viertens kann es für den praktischen Einsatz eines

Pflanzenbestimmungssystemen wichtig sein, welche Hard- und Softwareanforderungen und welche Rechenzeiten für die Modellbildung und -auswertung benötigt werden.

Hinsichtlich der Klassifikationsgüte können folgende Aussagen gemacht werden:

Aufgrund der durchgeführten Untersuchungen muß festgestellt werden, daß eine ausschließlich wissensbasierte und auf botanischen Bestimmungsschlüsseln aufbauende Auswertung der computerbildanalytisch erfassten Merkmale nicht sinnvoll ist. Es kann nur eine unzureichende Anzahl an Bestimmungsregeln verwendet werden. Viele Merkmale der Bestimmungsschlüssel von FITSCHEN (1994) oder GODET (1987) können mit herkömmlichen Bildverarbeitungsanlagen nicht oder nur unzureichend erfaßt werden. Es ist schwierig, die unscharf definierten Regeln der Bestimmungsschlüssel in ein zweiwertig orientiertes Regelsystem umzusetzen. Fehlberechnungen der Merkmale verschärfen dieses Problem. Die Regelsysteme erreichen dadurch die angestrebte Bestimmungsgenauigkeit nicht.

Aufgrund der schlechten Klassifikationsergebnisse sollte weiterhin auf eine zu starke statistisch orientierte Datenvorverdichtung vor dem Einsatz der jeweiligen Klassifikationsoperatoren verzichtet werden, da nur unnötige Informationsverluste entstehen. Insbesondere ist die Verwendung künstlicher Mittelwertbilder ungeeignet, hohe Klassifikationsergebnisse zu erzielen. Ein modellbasierter Mustervergleich mit künstlichen Vergleichsblättern ist wahrscheinlich ähnlich zu bewerten.

Ebenfalls unnötig ist nach den vorliegenden Ergebnissen die kanonische Vorverdichtung der computerbildanalytisch extrahierten Merkmale. Sie verbessern nicht - zumindest bei botanisch orientierter Merkmalextraktion - die Klassifikationsgüte nachgeschalteter Bestimmungsansätze, da dem eigentlichen Klassifikator weniger Information zur Verfügung steht. Die von einigen Autoren durchgeführte kanonische Vorverdichtung der Merkmale ist daher kritisch zu bewerten (vgl. z.B. PETRY 1989).

Eine mittlere bis gute Klassifikationsgüte mit jedoch zum Teil ungünstigen Abhängigkeiten von der Größe der Lerndatensätze erzielten die 3-nearest-neighbor-Klassifikation mit euklidischem Abstandsklassifikator, die quadratische Diskriminierung mit gruppeninterner Kovarianzmatrix und der Einsatz von Backpropagation-Netzwerken. Der Einsatz dieser drei Verfahren kann als problematisch eingestuft werden. Hier muß im Einzelfall geklärt werden, ob

die Größe des Lerndatensatzes, die Verteilung der Werte innerhalb der Gruppen und die Streuung der Daten eine Verwendung dieser Ansätze sinnvoll erscheinen läßt. In den vorliegenden Untersuchungen waren die Unterschiede der Ergebnisse zwischen diesen drei Varianten relativ gering.

Bessere Ergebnisse erzielte der speziell entwickelte fuzzy-logik-orientierte Klassifikationsansatz, die lineare Diskriminierung mit gepoolter Kovarianzmatrix und die parameterfreie 1-nearest-neighbor-Klassifikation mit euklidischem Abstand. Da die unterschiedlichen Ansätze zumindest bei Einsatz der maximalen Lerndatensatzgröße relativ ähnliche Klassifikationsergebnisse aufweisen, ist aufgrund der Klassifikationsgüte keine eindeutige Wertung für oder gegen eines dieser Verfahren zu machen. Gegen den Fuzzy-Klassifikator spricht jedoch die deutliche Ergebnisverschlechterung bei Verwendung weniger Lerndaten. Diese Aussage decken sich nur zum Teil mit bisherigen Aussagen aus der Literatur, wo einige Untersuchungen mit ähnlichen Aufgabenstellungen zeigten, daß zum Teil die besten Ergebnisse mit künstlich neuronalen Netzwerkansätzen erzielt wurden (siehe hierzu auch TIMMERMANS und HULZEBOSCH 1995, HOWARTH und SEARCY 1991 oder DECK et al. 1991). Bei SÖKEFELD et al. (1996) schnitt ein Fuzzy-Logik-Ansatz schlechter ab, was wahrscheinlich auf die Verwendung des Minimum-Operators zur Datenverdichtung zurückzuführen ist. Nach vorliegenden Ergebnissen ist der Mittelwert-Operator bei bildanalytischen Anwendungen besser geeignet. Grundsätzlich sind die einzelnen Anwendungen nur schwer miteinander zu vergleichen. Hinzu kommt, daß bei bisherigen Anwendungen nur geringer Wert auf die Analyse der Streuung der Ergebnisse bei unterschiedliche zusammengestellten Datensätzen gelegt wurde.

Vorliegende Untersuchungen verwendeten im Bereich des Pflanzenbaues außer der kanonischen Datenvorverdichtung nur wenig kombinierte Ansätze (z.B. BOCHEREAU et al. 1992). Da innerhalb der vorliegenden Untersuchungen eine botanisch inhaltlich orientierte Bildverarbeitung realisiert werden sollte, wurde der entwickelte wissenbasierte Ansatz mit den statistischen und Fuzzy-logik-orientierten Ansätzen gekoppelt. Es zeigt sich, daß eine solche Kopplung sinnvoll ist. In allen Fällen erzielten die Modelle unter Verwendung wissensbasierter Vorauswertung bessere Ergebnisse als der alleinige Einsatz der Modelle und als die Verwendung von Black-Box-Modellansätzen (zu berücksichtigen ist hierbei allerdings, daß bei der Bildung des wissensbasierten Modells alle Datensätze bekannt waren, die Bildung

der Vergleichsmodelle aber nur mit den Lerndatensätzen erfolgte). Die erzielbare Klassifikationsgüte bei Verwendung der kombinierten Ansätze hängt im besonderen Maße von den im wissensbasierten Teil verwendeten Regeln ab. Eine starke Eingrenzung der Lösungsmenge mit wissensbasierten Ansätzen birgt immer die Gefahr der fälschlich ausgeschlossenen richtigen Lösung mit sich. Da auch bei geringer Eingrenzung der Lösungsmenge die nachgeschalteten Ansätze immer noch die Möglichkeit haben, die richtige Lösung zu finden, sollte die Erstellung der Regelbasen sehr behutsam und wohl überlegt durchgeführt werden.

Eine weitere Beurteilung der vorgestellten Modellansätze mit mittlerer bis hoher Klassifikationsgüte anhand der Modellbildung ergibt folgendes Bild: Ein erstelltes Klassifikationsmodell benötigt bei der nearest-neighbor-Klassifikation alle kompletten Lerndatensätze zur Klassifikation eines anderen Blattes. Das heißt, jedes Blattmerkmal stellt ein Modellparameter dar. Bei parametrischen Modellen müssen zumindest die Kovarianzmatrizen und die Gruppenmittelwerte zur Klassifikation vorliegen, während bei neuronalen Netzen die gesamte Netzarchitektur und die Gewichtsmatrix zur Klassifikation benötigt wird. Für den entwickelten Fuzzy-logik-orientierten Ansatz reicht das Vorhandensein der Gruppenmittelwerte, Standardabweichungen und der z-Werte aus. Eine spezielle Entwicklung der Zugehörigkeitsfunktionen wie in klassischen Fuzzysystemen (siehe auch SIMONTON und GRAHAM 1996) ist nicht notwendig, da die Zugehörigkeitsfunktionen automatisch generiert werden. Hierdurch vereinfacht sich die Modellbildung deutlich, und sie muß nicht speziell auf jede neue Pflanzenart abgestimmt werden.

Bei einer sukzessiven Erstellung des Bestimmungsmodells ergibt sich aus den bisherigen Aussagen folgende Situation: Eine Modellerweiterung beim Einsatz des nearest-neighbor-Verfahrens ist relativ einfach. Die neuen Datensätze werden einfach zusätzlich in die Lernmenge mit aufgenommen. Die Klassifikation der übrigen Blätter wird durch die Erweiterung nur unwesentlich beeinflusst (wenn sich das neue Blatt bzw. die neue Art von den übrigen Blättern unterscheidet). Beim Einsatz des Fuzzy-Klassifikators kann ähnlich vorgegangen werden, nur daß für die entsprechende Pflanzenart die Mittelwerte und die Standardabweichungen neu berechnet werden müssen. Da durch Hinzunahme neuer Datensätze bzw. neuer Arten der optimale z-Wert der übrigen Blätter beeinflusst wird, sollten zumindest bei großen Erweiterungen die z-Werte aller Pflanzenarten neu optimiert werden. Bei Verwen-

dung des parametrischen Verfahrens muß bei einer Modellerweiterung die gesamte Kovarianzmatrix neu berechnet werden, was praktisch eine Veränderung des gesamten Bestimmungsmodells und damit eine erneute Überprüfung bedeutet. Noch problematischer ist die Situation bei Verwendung von neuronalen Netzansätzen. Hier muß sogar bei Hinzunahme eines Blattes zur Lernmenge die gesamte Netzstruktur einschließlich aller Netzgewichte neu aufgebaut und erlernt werden. Da bei der Bildung von künstlichen neuronalen Netzwerken dem Modellentwickler nahezu unendlich viele Modellvarianten und -konfigurationen zur Verfügung stehen, muß bei der sukzessiven Modellerstellung permanent getestet werden, welche Netze mit welchen Architekturen und Konfigurationen beste Ergebnisse liefern (zur weiteren Diskussion über die allgemeine Problematik bei der Erstellung neuronaler Netze zur Pflanzenklassifikation siehe RATH 1996a, RATH 1996b). Diese Tatsache wird in Untersuchungen vielfach nicht beachtet und führt gegenüber anderen Auswertansätzen, die eine fest vorgegebene Struktur aufweisen, zur falschen Bewertung des neuronalen Netzwerkansatzes.

In Bezug auf die Hard- und Softwareanforderungen und auf die on-line-Fähigkeit der einzelnen Ansätze ist festzustellen, daß in keinem Fall bei der gegenwärtig verfügbaren Rechnertechnik von Problemen auszugehen ist (im Bereich der Merkmalsextraktion sind die beschriebenen Verfahren jedoch zum Teil noch nicht on-line-tauglich). Bei sehr großen Systemen mit vielen Lernblättern und Merkmalen steigt bei Verwendung der nearest-neighbor-Klassifikation der Rechenaufwand proportional mit der Anzahl an Blättern bzw. Arten an, während bei den anderen Verfahren die notwendigen Rechnerkapazitäten nur von der Anzahl der Unterscheidungsgruppen abhängen. Insgesamt ist der Hardwareaufwand zur Bildung und Speicherung der Auswertemodelle bei dem beschriebenen Fuzzy-logik-orientierten Verfahren aufgrund der einfachen Modellstruktur und der geringen Anzahl an Modellparametern am geringsten.

Unter Berücksichtigung bisheriger Aussagen ergeben sich hinsichtlich der Modellauswahl zur Merkmalsauswertung folgende zusammenfassenden Schlußfolgerungen:

Zur Datenauswertung innerhalb von Pflanzenbestimmungssystemen sollten primär die Verfahren 'lineare Diskriminierung mit gepoolter Kovarianzmatrix', '1-nearest-neighbor-Klassifikation' und der beschriebene Fuzzy-logik-orientierte Klassifikator zum Einsatz kommen. Eine Aussage, welcher Ansatz bessere Ergebnisse liefert, ist im allgemeinen nicht

zu treffen, sondern hängt maßgeblich vom Einsatzfall und von den vorhandenen Daten ab. Insbesondere ist die Anzahl der zur Verfügung stehenden Lerndatensätze ein wichtiges, bei computerbildanalytischen Anwendungen aber häufig auch ein begrenzendes Kriterium. Nützliche Angaben zur Abhängigkeit der in dieser Arbeit verwendeten Klassifikatoren von der Größe des Lerndatensatzes finden sich bei SARUNAS und JAIN (1991).

Bei großen Datensätzen mit nicht gezielt auswählbaren Lerndaten sollte eventuell auf die 1-nearest-neighbor-Klassifikation verzichtet werden. Hier haben die beiden anderen statistisch orientierten Verfahren wahrscheinlich Vorteile. Bei sukzessiver Modellentwicklung und ungünstigen Verteilungen der Merkmale kann die lineare Diskriminierung zu arbeitsaufwendig werden, so daß der fuzzy-logik-orientierte Ansatz sinnvoller ist. Denkbar ist auch, mehrere Ansätze gleichzeitig parallel zu verwenden, um größere Sicherheiten in der Klassifikationsentscheidung zu erzielen. Dabei sollte ein Ansatz verwertet werden, der den Vergleich mit dem Einzelblatt ermöglicht. Ein anderer könnte gruppenspezifische Kennzahlen berücksichtigen. Die Verdichtung der zwei oder drei Ergebnisse könnte über deren Häufigkeiten erfolgen oder es wird eine erneute Bestimmung mit der verringerten Lösungsmenge mit einem statistischen Ansatz durchgeführt. Auf jeden Fall sind bei der Auswahl des Klassifikationsverfahrens die Größe des Lerndatensatzes und die Struktur der Klassifikatoren zu beachten.

### **7.3 Diskussion der Funktionalität des erstellten Systems**

Ein allgemeiner Vergleich zwischen den bisherigen Untersuchungen auf dem Gebiet der Pflanzenbestimmung und dem entwickelten System ist schwierig, da andere Arbeiten andere Untersuchungsobjekte und andere Techniken verwendeten und zum Teil andere Zielstellungen verfolgten. Der alleinige Vergleich der Klassifikationsergebnisse zeigt jedoch schon, daß das entwickelte System mit durchschnittlich 88 % richtiger Klassifikation bei 51 Pflanzenarten sowohl sehr gute Klassifikationsergebnisse als auch die meisten Pflanzenarten aufweist. Hinzu kommt, daß mit 21 verwendeten Blattparametern relativ wenig Kennzahlen zur Klassifikation verwendet wurden. Zum Vergleich: SÖKEFELD et al. (1996): 68 % , 26 Arten, 43 Parameter; WOEBBECKE et al. (1995): 60-90 %, 12 Arten, 5 Parameter. Insgesamt stellt das System eine Verbesserung gegenüber den bisherigen Ansätzen dar. Es ist

allerdings zu berücksichtigen, daß bei der vorliegenden Arbeit durch die eingesetzte Scannertechnik sehr gute Aufnahmequalitäten vorlagen, die eventuell bei anderen Untersuchungen mit Bilderfassung per CCD-Kamera nicht erzielt wurden.

Betrachtet man die im Anhang dargestellten Pflanzenarten und berücksichtigt die enorme Variabilität der Blätter innerhalb der einzelnen Arten, muß die Klassifikationsaufgabe als schwierig und hochgradig komplex eingestuft werden. Trotzdem wurde sie in fast 90 % der Fällen richtig gelöst. Berücksichtigt man noch, daß einige Arten visuell verwechselbare Blätter haben und nach FITSCHEN (1994) im wesentlichen nur anhand nicht blattorientierter Merkmale zu unterscheiden sind, kann insgesamt von einer sehr guten Lösung der gestellten Aufgabe ausgegangen werden. Inwieweit die Klassifikationsgüte für einen Praxiseinsatz ausreicht, kann nur in Verbindung mit dem unmittelbaren Einsatzbereich entschieden werden. An ein System zur Arten- und Sortendiskriminierung in einer biologischen Untersuchungsanstalt wird sicherlich eine andere Genauigkeitsanforderung gestellt als beim Einsatz eines Pflanzenbestimmungssystems zur Artbestimmung in der Landschaftskartierung.

#### **7.4 Einsatz und Nutzung der entwickelten Ansätze und des Gesamtsystems**

Das beschriebene System wurde prototypisch entwickelt. Den inhaltlichen und methodischen Aspekten wurde größere Bedeutung beigemessen als der Bedienungsfreundlichkeit. Insbesondere durch die daraus resultierende Verwendung mehrerer unterschiedlicher Hardwarekomponenten, Betriebssysteme und Softwaretools ist eine direkte Nutzung des Systems zur Zeit durch Dritte nicht möglich (wurde auch nicht angestrebt).

Die entwickelten Ansätze, Algorithmen und Programme lassen sich jedoch unmittelbar bei Pflanzenbestimmungsaufgaben verwenden. Denkbare Anwendungen sind (vgl. auch GEORG 1993):

- abgesetzte und direkte (online) Verfahren der Unkrautbonitierung (KÜHBAUCH 1996)
- Pflanzenerkennung und -bewertung zur Steuerung von gartenbaulichen Kulturmaßnahmen
- rechnergestützte Pflanzenkartierung im Umweltschutz und in der Landschaftspflege
- Pflanzenklassifikation und -einteilung zur Sortenprüfung und -genehmigung
- Hilfssysteme in der biologischen und pflanzenbaulichen Ausbildung

Ebenso können die Ansätze in anderen computerbildanalytischen Anwendungen verwertet werden. Der Einsatz in zeitkritischen Anwendungen (Maschinensteuerung o.ä.) kann allerdings nur hardwareorientiert erfolgen. Aufgrund momentan verfügbarer Hardwarebausteine ist dieses zumindest in Teilen möglich, wahrscheinlich aber noch mit einigem Aufwand verbunden. Bisherige Entwicklungen im Bereich der Computerbildanalyse haben gezeigt, daß, falls Ansätze zur prinzipiellen Lösung eines Problems vorhanden sind, die hardwareorientierte Umsetzung nur eine Frage der Zeit ist (vgl. on-line-Arbeiten aus Kapitel 2). Entscheidend ist, daß allgemeingültige und funktionsfähige Lösungsansätze existieren.

### **7.5 Zukünftige Entwicklungen, Verbesserungen und Visionen**

Die Untersuchungen verdeutlichten, daß eine rechnergestützte Pflanzenerkennung möglich und auch realisierbar ist. Zukünftige Entwicklungen sollten zwei Hauptrichtungen verfolgen:

1. Durch Entwicklungen im Bereich der Merkmalextraktion ist eine weitere Verbesserung der Stiel-, Blattachsen- und Blättchenerkennung usw. anzustreben. Besonders Fehler in Bereichen, die grundlegende Bildmerkmale wie Blattorientierung oder Blattausrichtung beeinflussen, lassen sich zum späteren Zeitpunkt durch Auswertemodelle nur schwer ausgleichen. Jede Verbesserung in den zentralen Bildaufbereitungsalgorithmen trägt unmittelbar zur Verbesserung der Klassifikationsmodelle bei. Da bei den bisherigen Arbeiten bereits erheblicher Optimierungsaufwand bezüglich der Bildung der Bildanalysealgorithmen betrieben wurde, ist jedoch zu prüfen, ob Aufwand und Nutzen in entsprechendem Verhältnis zueinander stehen. Entscheidungen in dieser Hinsicht können nur unter Vorgabe der notwendigen Klassifikationsgüte gemacht werden.

2. Durch weitere methodische Arbeiten muß versucht werden, standardisierte Verfahren der Datenauswertung auch auf Bereiche der Merkmalextraktion auszuweiten. Im Extremfall würde jeder einzelne Pixelgrauwert als Klassifikationsparameter in das Auswertemodell eingehen. Bildverarbeitungsalgorithmen würden dann nicht mehr benötigt. Die Datenverdichtung und -reduktion, die im beschriebenen Fall zum großen Teil von den bildanalytischen Algorithmen vollzogen wurde, würde vollständig von dem standardisierten Auswer-

temodell übernommen. Untersuchungen zur prinzipiellen Realisierbarkeit dieses Ansatzes wurden bereits erfolgreich bei kleinen Pixelbildchen und einfachen Strukturen mit neuronalen Netzen durchgeführt (vgl. z.B. RITTER et al. 1991). Statistische Verfahren zur Bearbeitung gesamter Bildmatrizen werden zur Zeit entwickelt (siehe z.B. PEI und LIN 1995). Eine abschließende Bewertung, insbesondere der Vergleich mit Klassifikationsmodellen, die mit konventioneller Bildverarbeitungstechnik entwickelt wurden, steht noch aus.

Auf jeden Fall bleibt festzuhalten, daß die automatische Nutzung visueller Informationen im Gartenbau keine Zukunftsvision ist, sondern in absehbarer Zeit verwirklicht werden kann. Ohne auf die zur Zeit sehr intensiv geführte Diskussion der Verwirklichung künstlicher Intelligenz näher einzugehen, steht fest, daß Computer in nicht allzu ferner Zukunft aufgrund ihrer höheren und (zumindest theoretisch) unbegrenzten Speicherfähigkeit und Vernetzbarkeit sämtliche streng formalisierbaren und auf menschlicher Wahrnehmung basierenden Aufgaben besser und effizienter lösen werden als der Mensch. Diese in gesellschaftlicher und individueller Hinsicht in vielen Bereichen problematische Vision eröffnet dem Gartenbau auch neue Möglichkeiten, wie z.B. die Einsparung von Pestiziden oder die optimale Ausnutzung von Ressourcen. Anliegen der vorliegenden Arbeit ist es, die Realisierung dieser Möglichkeiten forcieren.

## 8. Zusammenfassung

Am Beispiel der computergestützten Klassifikation von Laubgehölzen anhand ihrer Blätter werden methodische Untersuchungen zum Einsatz der Bildverarbeitung durchgeführt. Eingescannte Laubblätter von 51 verschiedenen Laubbaumarten wurden mit Hilfe speziell entwickelter Algorithmen aufbereitet und auf 21 botanisch orientierte Unterscheidungsmerkmale verdichtet (Blattstiellänge, Anzahl der Blättchen, Blattrandstruktur etc.). Innerhalb der Merkmalextraktion wurden hauptsächlich morphologische Bildverarbeitungsansätze verwendet, die mit geometrischen Verfahren gekoppelt wurden. Die Datenauswertung erfolgte mit unterschiedlichen statistischen, Fuzzy-logik-orientierten oder wissensbasierten Ansätzen und mit neuronalen Netzwerken. Beste Ergebnisse mit einer durchschnittlichen Klassifikationsgüte von ca. 88 % richtiger Klassifikation unbekannter Blätter wurden mit mehreren Auswertemodellen, im einzelnen mit linearer Diskriminanzfunktion, mit Fuzzy-Logik und mit

der nearest-neighbor-Klassifizierung (jeweils in Kombination mit einem vorgeschalteten wissensbasierten System) erzielt.

Aufgrund der Untersuchungen ergeben sich hinsichtlich der methodischen Ansätze folgende Schlußfolgerungen:

1. Es ist möglich, durch den Einsatz morphologischer Bildverarbeitung inhaltlich botanisch orientierte Merkmale aus Pflanzenbildern zu extrahieren. Zukünftige Arbeiten sollten diesem Aspekt mehr Bedeutung schenken. Die entwickelten Algorithmen lassen sich auf andere Anwendungsfälle übertragen.
2. Eine direkte Umsetzung verfügbarer Bestimmungsschlüssel mit Hilfe eines wissensbasierten Systems ist nicht möglich, da nicht alle notwendigen botanischen Informationen mit der eingesetzten Scannertechnik aufgenommen oder extrahiert werden können.
3. Mit dem speziell entwickelten Fuzzy-logik-orientierten Datenauswertungsansatz, bei dem die Zugehörigkeitsfunktionen automatisch aus statistischen Größen des Lerndatensatzes gewonnen werden, können gute Klassifikationsergebnisse erzielt werden, die jedoch von der Größe der Lerndatensätze abhängen.
4. Zur Datenauswertung sollten die aufgeführten Modellansätze in Kombination mit einer wissensbasierten Vorauswertung eingesetzt werden. Die Auswahl der Auswertemodelle sollte entsprechend dem Einsatzzweck und vor allem entsprechend der statistischen Zusammensetzung der zur Modellbildung zur Verfügung stehenden Datensätze erfolgen. Ferner ist auf die Möglichkeit der sukzessiven Modellbildung und Erweiterung zu achten.

## 9. LITERATUR

ABMAYR, W. 1994: Einführung in die digitale Bildverarbeitung. Teubner, Stuttgart.

ALCHANATIS, V.; K. PELEG und M. ZIV 1993: Classification of tissue culture segments by colour machine vision. *Journal of Agricultural Engineering Research*, 55 (4), S. 299-311.

AUDENAERT, J. A. R. 1996: Selektive Herbizidapplikation mit dem SELECTSPRAY-System. Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V. (Hrsg.): Innovative Verfahren zur Unkrauterkenung, Arbeitspapier 236, S. 95-100. Landwirtschaftsverlag, Münster-Hiltrup.

BACKHAUS, K.; B. ERICHSON; W. PLINKE und R. WEIBER 1990: Multivariate Analysemethoden. Springer, Berlin.

BALDOCK, R. A. 1992: Trainable models for the interpretation of biomedical images. *Image and vision computing*, 10 (6), S. 444-450.

BENNEDSEN, B. S. 1992: Plant monitoring by machine vision. *Acta Horticulturae*, 304, S. 173-181.

BEN-HANAN, U., P.O. GUTMAN und K. PELEG 1991: Classification of apples with a neural network based classifier. Mathematic and control applications in agriculture and horticulture. Proceedings IFAC-ISHS workshop 30.09.-03.10.1991, Matsuyama, Japan.

BILLER, R. H. 1996: Optoelektronik zur Unkrauterkenung - erste Erfahrungen beim Test unter simulierten Bedingungen und beim Einsatz auf Versuchsflächen. Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V. (Hrsg.): Innovative Verfahren zur Unkrauterkenung, Arbeitspapier 236, S. 75-85. Landwirtschaftsverlag, Münster-Hiltrup.

BOCHEAREAU, L., P. BOURGINE und B. PALAGOS 1992: A method for prediction by combining data analysis and neural networks: application to prediction of apple quality using near infra-red spectra. *Journal of Agricultural Engineering Research*, 51, S. 207-216.

BOCK, H. H. 1974: Automatische Klassifikation. Theoretische und praktische Methoden zur Gruppierung und Strukturierung von Daten. Vandenhoeck und Ruprecht, Göttingen.

BOTHE, H.-H. 1995: Fuzzy Logic - Einführung in Theorie und Anwendungen. Springer, Berlin.

BRONSTEIN, I.N. und K.A. SEMENDJAJEW 1987: Taschenbuch der Mathematik. Harri Deutsch, Thun und Frankfurt/Main.

BURMEISTER, A. 1996: Automatische Gewinnung von Farbbildern zur Pflanzenerkennung. Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V. (Hrsg.): Innovative Verfahren zur Unkrauterkenung, Arbeitspapier 236, S. 59-70. Landwirtschaftsverlag, Münster-Hiltrup.

CARL, S., R. KRAFT und M. PRECHT 1993: Fraktale Dimension von Wurzelsystemen. Schulze E., B. Petersen und H. Geidel (Hrsg.): Berichte der Gesellschaft für Informatik in der Land-, Forst- und Ernährungswirtschaft, Band 5, S. 107-113. Gesellschaft für Informatik in der Land-, Forst- und Ernährungswirtschaft (GIL).

CRITTEN, D.L. 1996: Fourier based techniques for the identification of plants and weeds. *Journal of Agricultural Engineering Research*, 64, S. 149-154.

DECK, S., C.T. MORROW, P.H. HEINEMANN und H.J. SOMMER 1991 III: Neural networks versus traditional classifiers for machine vision inspection. ASAE-paper no. 91-3502. American Society of Agricultural Engineers.

DEICHSEL G. und H.J. TRAMPISCH 1985: Clusteranalyse und Diskriminanzanalyse. Fischer Verlag, Stuttgart.

DELTA-T DEVICES 1996: Produktinformation der Firma Delta-T Devices Ltd. GB-Cambridge.

DRECHSEL, D. 1996: Regelbasierte Interpolation und Fuzzy-Control. Viehweg, Braunschweig/Wiesbaden.

DUFNER, J., U. JENSEN und E. SCHUHMACHER 1992: Statistik mit SAS. Teubner, Stuttgart.

ECKHARDT U. 1988: Verdünnung mit perfekten Punkten. In: BUNKE, H., O. KÜBLER und P. STUCKI (Hrsg.): Mustererkennung 1988, 10.Proceedings, DAGM-Symposium, Zürich, 27.29. September 1988. Springer, Berlin.

ECKSTEIN, W. 1993: HORUS-Referenzmanual, Version 3.14. Technische Universität München, Fakultät für Informatik, München.

EVERS, H., G. PÄTZOLD, H. W. SEIBOLD, H.-P. LIEBIG und D. ERNST 1987: Die Biomassebestimmung an Pflanzen mit Hilfe der Computerbildanalyse. *Gartenbauwissenschaft*, 52 (3), S. 119-124.

FEHR, B. W. und J. B. GERRISH 1995: Vision-guided row-crop follower. *Applied Engineering in Agriculture*, 11 (4), S. 613-620.

FITSCHEN, J. 1994: Gehölzflora: ein Buch zum Bestimmen der in Mitteleuropa wildwachsenden und angepflanzten Bäume und Sträucher. Quelle und Meyer, Heidelberg.

FRANZ, E., M. R. GEBHARDT und K. B. UNKLESBAY 1995: Algorithms for extracting leaf boundary information from digital images of plant foliage. *Transactions of the ASAE*, 38 (2), S. 625-633.

FU, L.-M. 1990: Analysis of the dimensionality of neural networks for pattern recognition. *Pattern recognition*, 23 (10), S. 1131-1140.

GEORG H. 1993: Digitale Bildverarbeitung im Agrarbereich unter spezieller Berücksichtigung der Entwicklung eines Systems zur Erkennung von Ackerunkräutern. Dissertation Justus-Liebig-Universität, Gießen.

GEORG, H., F.J. BOCKISCH und A. KRIETE (1992): Automatische Unkrautererkennung. *Landtechnik*, 47 (3), S. 113-115.

GHAZANFARI A. und J. IRUDAYARAJ 1996: Classification of pistachio nuts using a string matching technique. *Transactions of the ASAE*, 39 (3), S. 1197-1202.

GODET, J.-D. 1987: Bäume und Sträucher: Einheimische und eingeführte Baum- und Straucharten. Arboris-Verlag, Hinterkappelen-Bern.

GODET, J.D. 1995: Knospen und Zweige der einheimischen Baum- und Straucharten: ein Bestimmungsbuch für 150 Gehölze. Naturbuch-Verlag, Augsburg.

GUYER, D.E., G.E. MILES und M.M. SCHREIBER 1984: Computer vision and image processing for plant identification. ASAE-paper no. 84-1632. American Society of Agricultural Engineers.

GUYER, D.E., G.E. MILES, L. D. GAULTNEY und M.M. SCHREIBER 1993: Application of machine vision to shape analysis in leaf and plant identification. *Transactions of the ASAE*, Vol. 36 (1), S. 163-171.

HACK, G. 1992: On-line measurements of plant growth in the greenhouse. *Acta Horticulturae*, 230, S. 337-343.

HACK, G. und RATH, T. 1992: Die Computerbildanalyse - Automatisierungstechnik der Zukunft, *Deutscher Gartenbau*, 46 (38), S. 2328-2331.

HARALICK, R.M., S.R. STERNBERG und X. ZHUANG 1987: Image Analysis Using Mathematical Morphology. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. PAMI-9, No. 4., S. 532-549.

HARMON, P. und D. KING 1989: Expertensysteme in der Praxis: Perspektiven, Werkzeuge, Erfahrungen. Oldenbourg, München.

- HETZRONI, A. und G.E. MILES (1992): Machine vision monitoring of plant health. ASAE-paper no. 92-3574. American Society of Agricultural Engineers.
- HOTHER, K., B. HEROLD und M. GEYER 1995: Grenzen der Erkennung von Qualitätsfehlern im Apfelpewebe bei Messung der spektralen Reflexion. *Gartenbauwissenschaft*, 60 (4), S. 162-166.
- HOWARTH, M.S., S.W. SEARCY 1991: Comparison of Bayesian and neural network classifiers for grading carrots. ASAE-paper no. 91-7012. American Society of Agricultural Engineers.
- HUANG, Q., J. R. LORCH und R. C. DUBES 1994: Can the fractal dimension of images be measured? *Pattern recognition*, 27 (3), S. 339-349.
- HUMPHRIES, S. und W. SIMONTON 1993: Identification of plant parts using color and geometric image data. *Transactions of the ASAE*, 36 (5), S. 1493-1500.
- INFORM 1992: fuzzyTech 2.2, Handbuch und Referenz. Inform GmbH, Aachen.
- JANG B.-K. und R.T. CHIN 1990: Analysis of Thinning Algorithms Using Mathematical Morphology. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 12, No. 6., S. 541- 551.
- JUNGMANN B. 1984: Segmentierung mit morphologischen Operationen. W. Klopatsch (Hrsh.): Mustererkennung 1984, Informatik Fachberichte, S. 77-83.
- KAINDL, H. 1989: Problemlösen durch heuristische Suche in der Artificial Intelligence. Springer, Wien.
- KAUFMANN, A. 1975: Theory of Fuzzy Subsets. Academic Press, New York.

KEICHER, R.; H. SEUFERT und H. KNECHTGES (1995): Digitale Bildverarbeitung als Sensor zur Reihenerkennung. Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V. (Hrsg.): Mechanische Unkrautregulierung, Arbeitspapier 222, S. 121-131.

Landwirtschaftsverlag, Münster-Hiltrup.

KOPLowitz, J. und S. PLANTE 1995: Corner detection for chain coded curves. *Pattern recognition*, 28 (6), S. 843-852.

KRATZER, K.P. 1993: Neuronale Netze: Grundlagen und Anwendungen. Hanser, München, Wien.

KRUSE, R. 1986: Unschärfe-Repräsentation und Unschärfe-Fortpflanzung in Expertensystemen. Abschlußbericht TIRF 33/E0002/E1302. Dokumentationszentrum der Bundeswehr, Lfd. Nr. FW 0035, Bonn.

KÜHBAUCH, W. 1996: Anwendungsperspektiven der sensorgesteuerten Unkrautkontrolle. Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V. (Hrsg.): Innovative Verfahren zur Unkrauterkenung, Arbeitspapier 236, S. 9-21. Landwirtschaftsverlag, Münster-Hiltrup.

KULKARNI, A.D. 1994: Artificial neural networks for image understanding. Van Nostrand Reinhold, New York.

KULL U. und A. HERBIG 1995: Das Blattadersystem der Angiospermen: Form und Evolution. *Naturwissenschaften*, 82, S. 441-451.

LIAO, K., M.R. PAULSEN, J.F. REID, B.C. NI und E.P. BONIFACIO-MAGHIRANG 1993: Corn kernel breakage classification by machine vision using a neural network classifier. *Transactions of the ASAE*, 36, 6, S. 1949-1953.

LIAO, K., M.R. PAULSEN und J.F. REID 1994: Real-time detection of colour and surface defects of maize kernels using machine vision. *Journal of Agricultural Engineering Research*, 59, S. 263-271.

LING, P. P. und V. N. RUZHITSKY 1996: Machine vision techniques for measuring the canopy of tomato seedling. *Journal of Agricultural Engineering Research*, 65, S. 85-95.

LIU, H.C. und M.D. SRINATH 1990: Corner detection from chain-code. *Pattern recognition*, 23 (1/2), S. 51-68.

LOW, A. 1991: Introductory computer vision and image processing. McGraw Hill, London.

MARAGOS P. 1989: Pattern spectrum and multiscale shape representation. *IEEE transactions on pattern analysis and machine intelligence*, 11 (7), S. 701-716.

MASSEN, R. 1996: Colour Brain - eine neue Echtzeit-Farbbildverarbeitungstechnologie für komplexe Erkennungsaufgaben bei der Unkrautbekämpfung. Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V. (Hrsg.): Innovative Verfahren zur Unkrauterkenung, Arbeitspapier 236, S. 35-40. Landwirtschaftsverlag, Münster-Hiltrup.

MAYER 1992: Produktinformation. Firma Mayer, D-Heidenheim.

MCCULLOCH, W.S. und W. PITTS 1943: A logical calculus of the ideas immanent in nervous activity. *Bull. math. Biophys*, 5, 115-133.

MCDONALD, T. und Y.R. CHEN 1990: Application of morphological image processing in agriculture. *Transactions of the ASAE*, 33 (4), S. 1345-1352.

MEULEMANN 1995: Produktinformation. Firma Meulemann, NL-Wageningen.

MINISTERIUM FÜR WIRTSCHAFT, MITTELSTAND UND TECHNOLOGIE DES LANDES  
NORDRHEIN-WESTFALEN 1995: Stand und Trends der Bildverarbeitung in NRW,  
Anwendungsgebiete, Problemlösungen, Potentiale. Ministerium für Wirtschaft, Mittelstand  
und Technologie des Landes Nordrhein-Westfalen, Düsseldorf.

MITCHELL, A. und J. WILKINSON 1982: Pareys Buch der Bäume: Nadel- und Laubbäume in Europa nördlich des Mittelmeeres. Parey, Hamburg.

MOLLER NIELSEN, H., W. PAUL und M. KRAFT 1995: Bildverarbeitung zum Erkennen von Fahrspuren, Pflanzenreihen und Einzelpflanzen. Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V. (Hrsg.): Mechanische Unkrautregulierung, Arbeitspapier 222, S. 111-120. Landwirtschaftsverlag, Münster-Hiltrup.

MOLTO, E., F. PLA und F. JUSTE 1992: Vision Systems for the Location of Citrus Fruit in a Tree Canopy., *Journal of Agricultural Engineering Research*, 52, S. 101-110.

NAKANO, K., K.I.TAKIZAWA und Y. OHTSUKA 1995: The application of neural network systems to the evaluation of the quality of fruits. Udink ten Cate, A.J., R. Martin-clouaire, A.A. Dijkhuizen und C. Lokhorst (Hrsg.); Artificial Intelligence in Agriculture. 2nd IFAC/IFIP/EurAgEn Workshop on Artificial Intelligence in Agriculture, S. 209-214. Elsevier, Oxford.

NEGOITA, C.V. 1985: Expert Systems and Fuzzy Systems. Benjamin/Cummings, Menlo Park, Ca.

NIEMANN, H. 1985: Wissensbasierte Bildanalyse. *Informatik-Spektrum*, 8, S. 201-214.

OLIMEX 1995: Produktinformation. Firma Olimex, NL-Aalsmeer.

PAVLIDIS, T. 1982: Algorithms for Graphics and Image Processing. Springer, Berlin.

PHAM, D.T. und P.T.N. PHAM 1988: Expert systems: A review. In: PHAM D.T. (Hrsg.): Expert systems in engineering. Springer, Berlin.

PEDRYCZ W. 1990: Fuzzy sets in pattern recognition: methodology and methods. *Pattern recognition*, 23 (1/2), S. 121-146.

- PEI, S.C. und C.N. LIN 1995: Image normalization for pattern recognition. *Image and Vision Computing*, 13 (10), S. 711-723.
- PETRY, W. 1989: Unkrautkontrolle im landwirtschaftlichen Pflanzenbau mit Hilfe der quantitativen Bildanalyse. Dissertation Universität Bonn.
- POGGIO, T. und D. BEYMER 1996: Learning to see. *IEEE spectrum*, may 1996, S. 60-69.
- PRECHT, M. 1987: Bio-Statistik. Oldenbourg, München.
- PULITI P. und G. TASCINI 1993: Knowledge-based approach to image interpretation. *Image and vision computing*, 11 (3), S. 122-128.
- QIU, W. und S.A. SHEARER 1992: Maturity Assessment of Broccoli Using the Discrete Fourier Transform. *Transactions of the ASAE*, 35 (6), S. 2057-2062.
- RATH, T. 1992: Einsatz wissensbasierter Systeme zur Modellierung und Darstellung von gartenbautechnischem Fachwissen am Beispiel des hybriden Expertensystems HORTEX. Gartenbautechnische Informationen, Heft 34. Institut für Technik in Gartenbau und Landwirtschaft, Universität Hannover, Hannover.
- RATH, T. 1994: Computerbildanalyse im Gartenbau. *Gärtnerbörse*, 94 (30), S. 1483-1486.
- RATH, T. 1995a: Auswertung bildanalytischer Daten mit neuronalen Netzwerken. In: Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V. (Hrsg.): Mechanische Unkrautregulierung, Arbeitspapier 222, S. 132-143. Landwirtschaftsverlag, Münster-Hiltrup.
- RATH, T. 1995b: Artificial neural networks for plant classification with image processing. Udink ten Cate, A.J., R. Martin-clouaire, A.A. Dijkhuizen und C. Lokhorst (Hrsg.); Artificial Intelligence in Agriculture. 2nd IFAC/IFIP/EurAgEn Workshop on Artificial Intelligence in Agriculture, S. 197-202. Elsevier, Oxford.

RATH, T. 1996a: Pflanzenidentifikation mit neuronalen Netzwerken und mit Fuzzy-Logik - ein Vergleich. Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V. (Hrsg.): Innovative Verfahren zur Unkrautererkennung, Arbeitspapier 236, S. 41-46. Landwirtschaftsverlag, Münster-Hiltrup.

RATH, T. 1996b: Computerbildanalyse gartenbaulicher Objekte mit morphologischen Operatoren. Bornimer Agrartechnische Berichte, Heft 11, S. 37-49, Institut für Agrartechnik Bornim e.V., Potsdam-Bornim.

RATH, T. 1996c: Klassifikation und Identifikation gartenbaulicher Objekte mit künstlichen neuronalen Netzwerken. *Gartenbauwissenschaft*, 61 (4), S. 153-159.

RIGNEY, M. P. und G. A. KRANZLER 1988: Machine vision for grading southern pine seedlings. *Transactions of the ASAE*, 31 (2), S. 642-646.

RITTER, H., T. MARTINEZ und K. SCHULTEN 1991: Neuronale Netze: eine Einführung in die Neuroinformatik selbstorganisierter Netzwerke. Addison-Wesley, Bonn, München.

ROTH, M. 1996: Effiziente Techniken zur Lösung geometrischer Probleme. *mc extra*, 1/96, 34-40.

ROSIN P. L. und T. ELLIS 1991: Frame-based system for image interpretation. *Image and vision computing*, 9 (6), S. 353-361.

RUMELHART, D.E., G.E. HINTON und R.J. WILLIAMS 1986: Learning Representations by Back-Propagating Errors. *Nature*, 323, S. 533-536.

SARIG, Y. (1993): Robotics of Fruit Harvesting: A State-of-the-art Review. *Journal of Agricultural Engineering Research*, 54, S. 265-280.

SARUNAS, J. R. und A. K. JAIN 1991: Small sample size effects in statistical pattern recognition: recommendations for practitioners. *IEEE transactions on pattern analysis and machine intelligence*, 13 (3), S. 252-264.

SAS 1994: SAS/STAT User`s Guide, Version 6, 4. Edition, Vol. 1 und Vol. 2. SAS Institute Inc., Cary, NC.

SCHAUFLER, D. H. und P. N. WALKER 1995: Micropropagated sugarcane shoot identification using machine vision. *Transactions of the ASAE*, 38 (6), S. 1919-1925.

SCHÖNEBURG, E., N. HANSEN und A. GAWELCZYK 1990: Neuronale Netzwerke: Einführung, Überblick und Anwendungsmöglichkeiten. Markt&Technik, Haar bei München.

SCHUEMER, R., G. STRÖHLEIN und J. GOGOŁOK 1990: Datenverarbeitung und statistische Auswertung mit SAS, Bd 1: SAS Versionen 5 (Großrechner) und 6 (PC). Fischer, Stuttgart, New York.

SERRA, J. 1982: Image analysis and mathematical morphologie. Academic press, London.

SHATADAL, P., D. S. JAYAS und N. R. BULLEY 1995: Digital image analysis for software separation and classification of touching grains: I. disconnect algorithm. *Transactions of the ASAE*, 38 (2), S. 635-643.

SHEARER, S. A. und F. A. PAYNE 1990: Color and defect sorting of bell peppers using machine vision. *Transactions of the ASAE*, 33 (6), S. 2045-2050.

SHEARER S. A. und R. G. HOLMES 1990: Plant identification using color co-occurrence matrices. *Transactions of the ASAE*, 33 (6), S. 2037-2044.

SHIMIZU, H., R.D. HEINS 1995: Computer-vision-based system for plant growth analysis. *Transactions of the ASAE*, 38 (3), S. 959-964.

SIMONTON, W. und D. GRAHAM 1996: Bayesian and fuzzy logic classification for plant structure analysis. *Applied Engineering in Agriculture*, 12 (1), S. 89-97.

SIMONTON, W. und J. PEASE 1993: Orientation independent machine vision classification of plant parts. *Journal of Agricultural Engineering Research*, 54, S. 231-243.

SÖKEFELD, M., R. GERHARDS und W. KÜHBAUCH 1996: Automatische Erkennung von Unkräutern im Keimblattstadium mit digitaler Bildverarbeitung. Kuratorium für Technik und Bauwesen in der Landwirtschaft e.V. (Hrsg.): Innovative Verfahren zur Unkrautererkennung, Arbeitspapier 236, S. 47-58. Landwirtschaftsverlag, Münster-Hiltrup.

STEINHAUSEN, D. und K. LANGER 1977: Clusteranalyse: Einführung in Methoden und Verfahren der automatischen Klassifikation. de Gruyter, Berlin, New York.

STEINMETZ, V., M. J. DELWICHE, D. K. GILES und R. EVANS 1994: Sorting cut roses with machine vision. *Transactions of the ASAE*, 37 (4), S. 1347-1353.

STERNBERG, S. R. 1986: Grayscale Morphology. *Computer vision, graphics and image processing*, 35, S. 333-355.

STRUNZ, H. 1977: Entscheidungstabellentechnik. Carl Hanser, München.

TAO, Y., P. H. HEINEMANN, Z. VARGHESE, C. T. MORROW und H. J. SOMMER III 1995a: Machine vision for color inspection of potatoes and apples. *Transactions of the ASAE*, 38 (5), S. 1555-1561.

TAO, Y., C. T. MORROW, P. H. HEINEMANN, und H. J. SOMMER III 1995b: Fourier-based separation technique for shape grading of potatoes using machine vision. *Transactions of the ASAE*, 38 (3), S. 949-957.

TILLET, R.D. 1991: Image Analysis for Agricultural Processes: a Review of Potential Opportunities. *Journal of Agricultural Engineering Research*, 50, S. 247-258.

TIMMERMANS, A.J.M. und A.A. HULZEBOSCH 1995: On-line sorting of pot plants with a neural network classifier. Udink ten Cate, A.J., R. Martin-clouaire, A.A. Dijkhuizen und C. Lokhorst (Hrsg.); Artificial Intelligence in Agriculture. 2nd IFAC/IFIP/EurAgEn Workshop on Artificial Intelligence in Agriculture, S. 203-208. Elsevier, Oxford.

TROOIJEN, T. P. und D. F. HEERMANN 1992: Measurement and simulation of potato leaf area using image processing. III. Measurement. *Transactions of the ASAE*, 35 (3), S. 1719-1721.

TRUPPEL, I. und B. HEROLD 1996: Bedeutung von Licht und Farbe für die Qualitätsbeurteilung von Früchten mittels Computerbildanalyse. Bornimer Agrartechnische Berichte, Heft 11, S. 61-73, Institut für Agrartechnik Bornim e.V., Potsdam-Bornim.

VAN DE VOOREN, J.G., G. POLDER und G.W.A.M. VAN DER HEIJDEN 1991: Application of image analysis for variety testing of mushroom. *Euphytica*, 57, S. 245-250.

VISSER 1995: Produktinformation. Firma Visser, NL-`s-Gravendeel.

WIELEMAKER, J. 1992: SWI-Prolog 1.6 - Reference Manual. University of Amsterdam, Dept. of Social Science Informatics, Amsterdam.

WILHOIT, J. H., R.K. BYLER, M.B. KOSLAV und D.H. VAUGHAN 1990: Broccoli head sizing using image textural analysis. *Transactions of the ASAE*, 33 (5), S. 1736-1740.

WILHOIT, J. H., L. J. KUTZ, D. E. FLY und D. B. SOUTH 1994: Pc-based multiple camera machine vision systems for pine seedling measurements. *Applied Engineering in Agriculture*, 10 (6), S. 841-847.

WHITTAKER, A.D.; G.E. MILES; O.R. MITCHELL und L.D. GAULTNEY 1987: Fruit Location in a Partially Occluded Image. *Transactions of the ASAE*, 30 (3), S. 591-596.

WOBEBECKE, D.M., G.E. MEYER, K. VON BARGEN und D. A. MORTENSEN 1995: Shape features for identifying young weeds using image analysis. *Transactions of the ASAE*, 38 (1), S. 271-281.

WOLFE, R. R. und M. SWAMINATHAN 1987: Determining orientation and shape of bell peppers by machine vision. *Transactions of the ASAE*, 30 (6), S. 1853-1856.

YANG, Q. 1993: Classification of apple surface features using machine vision and neural networks. *Computers and Electronics in Agriculture*, 9 (1), S. 1-12.

YANG, Q. 1996: Apple stem and calyx identification with machine vision. *Journal of Agricultural Engineering Research*, 63 , S. 229-236.

YONEKAWA, S., N. SAKAI und O. KITANI 1996: Identification of idealized leaf types using simple dimensionless shape factors by image analysis. *Transactions of the ASAE*, 39 (4), S. 1525-1533.

ZADEH, L.A. 1965: Fuzzy sets. *Information and Control*, 8, S. 338-353.

ZADEH, L.A. 1975: Calculus of fuzzy restrictions. In: ZADEH, L.A., K.S. FU, K. TANAKA und M. SHIMURA (Hrsg.): *Fuzzy Sets and Their Applications to Cognitive and Decision Processes*. Academic Press, New York.

ZAMPERONI 1991: *Methoden der digitalen Bildverarbeitung*. Vieweg, Braunschweig.

ZAYAS, I., H. CONVERSE und J. STEELE 1990: Discrimination of whole from broken corn kernels with image analysis. *Transactions of the ASAE*, 33 (5), S. 1642-1646.

ZAYAS, I., F. S. LAI und Y. POMERANZ 1986: Discrimination between wheat classes and varieties by image analysis. *Cereal chemistry*, 63 (1), S. 52-56.

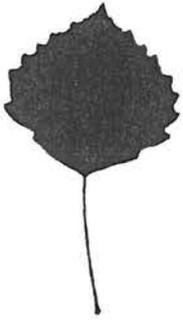
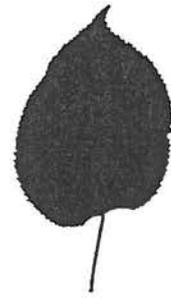
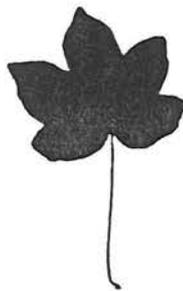
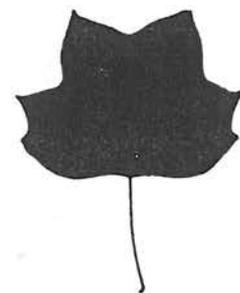
ZELL, A., G. MAMIER, M. VOGT, N. MACHE, R. HÜBNER, K.U. HERRMANN, T. SOYEZ, M. SCHMALZL, T. SOMMER, A. HATZIGEORGIU, S. DÖRING, D. POSSELT, M. RECZKO, M. RIEDMILLER, M. SEEMANN, M. RITT und J. DECOSTER 1994: SNNS, Stuttgart Neural Network Simulator, User Manual, Version 3.2, Report 3/94. Institute for Parallel and Distributed High-Performance Systems, University of Stuttgart, Stuttgart.

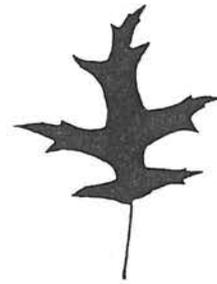
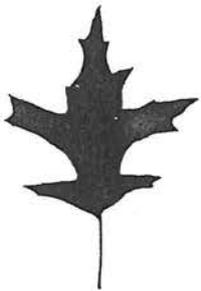
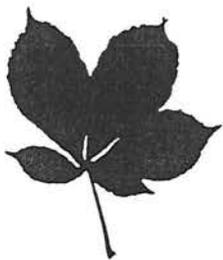
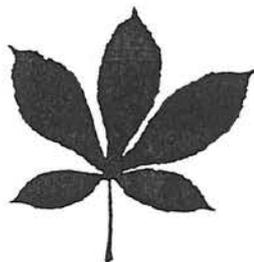
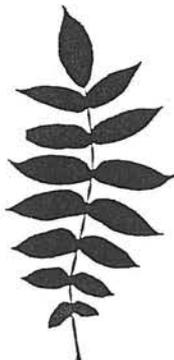
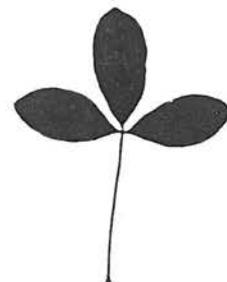
ZHANG, N. und C. CHAISATTAPAGON 1995: Effective criteria for weed identification in wheat fields using machine vision. *Transactions of the ASAE*, 38 (3), S. 965-974.

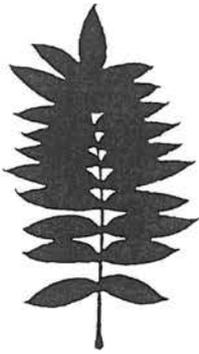
ZWIGGELAAR, R., Q. YANG, E. GARCIA-PARDO und C.R. BULL 1996: Use of spectral information and machine vision for bruise detection on peaches and apricots. *Journal of Agricultural Engineering Research*, 63 , S. 323-332.

## Anhang: Binärbilder eingescannter Arten (auf einheitliche Größe skaliert und ausgerichtet)

1. *Acer carpinifolium*2. *Alnus glutinosa*3. *Alnus incana*4. *Betula pendula*5. *Betula platyphylla*6. *Betula pubescens*7. *Carpinus betulus*8. *Castanea sativa*9. *Cercidiphyllum japonicum*10. *Cercis siliquastrum*11. *Corylus avellana*12. *Corylus colurna*13. *Fagus sylvatica*14. *Ginkgo biloba*15. *Magnolia kobus*16. *Populus lasiocarpa*

17. *Populus tremula*18. *Prunus serotina*19. *Pyrus communis*20. *Salix alba*21. *Salix fragilis*22. *Sorbus aria*23. *Tilia cordata*24. *Tilia platyphyllos*25. *Ulmus laevis*26. *Acer campestre*27. *Acer ginnala*28. *Acer platanoides*29. *Acer pseudoplatanus*30. *Acer saccharinum*31. *Crataegus monogyna*32. *Liriodendron tulipifera*

33. *Platanus x acerifolia*34. *Populus nigra*35. *Quercus cerris*36. *Quercus coccinea*37. *Quercus palustris*38. *Quercus robur*39. *Quercus rubra*40. *Sorbus intermedia*41. *Aesculus hippocastanum* (gelapptes Blatt)42. *Aesculus hippocastanum* (gefingertes Blatt)43. *Carya cordiformis*44. *Fraxinus excelsior*45. *Gleditsia triacanthos*46. *Juglans cinerea*47. *Juglans regia*48. *Laburnum anagyroides*



49. *Pterocarya fraxinifolia*



50. *Robinia pseudoacacia*



51. *Sophora japonica*



52. *Sorbus aucuparia*

Bauplan und Bezeichnungen von Laubblättern (Quelle: FITSCHEN 1994)

