

# **Vergleich unterschiedlicher Algorithmen zur Unterkiefersegmentierung CT- und MRT- basierter Datensätze von Schweinekadavern: Semiautomatische versus automatisierte Anwendungen**

Matthias M. X. Herrmann

Vollständiger Abdruck der von der TUM School of Medicine and Health der  
Technischen Universität München zur Erlangung eines  
Doktors der Medizin (Dr. med.)  
genehmigten Dissertation.

Vorsitz: apl. Prof. Dr. Stefan Thorban

Prüfer der Dissertation:

1. Priv.-Doz. Dr. Dr. Lucas M. Ritschl
2. Priv.-Doz. Dr. Dennis M. Hedderich

Die Dissertation wurde am 30.08.2023 bei der Technischen Universität München  
eingereicht und durch die TUM School of Medicine and Health am 13.03.2024  
angenommen.



# Inhaltsverzeichnis

<i>I. Abbildungsverzeichnis</i>	5
<i>II. Tabellenverzeichnis</i>	7
<i>III. Abkürzungsverzeichnis</i>	8
<b>1 Einleitung</b>	<b>9</b>
1.1 Segmentierung	9
1.1.1 Konventionelle Segmentierungsalgorithmen	10
1.1.2 Automatisierte/Interaktive Segmentierungsalgorithmen	15
1.2 CAD/CAM-Chirurgie	17
1.2.1 Grundlagen der CAD/CAM-Chirurgie	17
1.2.2 Unterkieferrekonstruktion als Anwendungsbeispiel der CAD/CAM-Chirurgie	20
1.2.3 Bildgebung in der CAD/CAM-Chirurgie	23
<b>2 Zielsetzung</b>	<b>25</b>
<b>3 Material und Methoden</b>	<b>26</b>
3.1 Ethikvotum und Tierschutz	26
3.2 Studiendesign	26
3.3 Material	27
3.3.1 CT-Bildgebung	28
3.3.2 MRT-Bildgebung	28
3.3.3 Optische 3D-Scans der Schweinekiefer	29
3.3.4 Verwendete Computer und Programme	30
3.4 Methoden	30
3.4.1 Zeitmessung	31
3.4.2 Semiautomatischer Segmentierungsalgorithmus	31
3.4.3 Automatisierter Segmentierungsalgorithmus	41
3.4.4 Nachbearbeitung	50
3.4.5 Bestimmung der Oberflächenvergleichsparameter in MeshLab	52
3.5 Statistische Auswertung	56
<b>4 Ergebnisse</b>	<b>58</b>
4.1 Interrater- und Intrarater-Korrelationskoeffizient	58
4.2 Isolierter Vergleich der Modalitäten und Algorithmen	58
4.2.1 Oberflächenvergleich	58
4.2.2 Segmentierungszeit	59
4.3 Kombierter Vergleich der Modalitäten und Algorithmen	61
4.3.1 Oberflächenvergleich	61
4.3.2 Segmentierungszeit	65
<b>5 Diskussion</b>	<b>67</b>
5.1 Interrater- und Intrarater-Korrelationskoeffizient	67

5.2	Einordnung der geometrischen Abweichungen innerhalb vergleichbarer Studien _____	67
5.3	Bewertung der geometrischen Abweichungen innerhalb dieser Studie____	71
5.4	Zeitliche Komponente _____	75
5.5	Limitationen der Studie _____	77
6	<i>Zusammenfassung</i> _____	79
7	<i>Literaturverzeichnis</i> _____	81
8	<i>Danksagung</i> _____	92

# I. Abbildungsverzeichnis

<b>Abbildung 1:</b> Hounsfield-Skala ( <i>in Anlehnung an Abt. für Unterricht und Medien AUM, 2016</i> ) _____	11
<b>Abbildung 2:</b> Histogramme zweier Beispielbilder _____	12
<b>Abbildung 3:</b> Skizze des Region Growing Prozesses (Imdad et al., 2019) _____	13
<b>Abbildung 4:</b> Funktionsweise der Wasserscheidentransformation (Sugg, 2005) _____	15
<b>Abbildung 5:</b> Skizze des Random-Walker-Algorithmus (Preim & Botha, 2013) _____	16
<b>Abbildung 6:</b> Virtuelle Planung der Schnittführung am bereits segmentierten Unterkiefer eines Patienten _____	20
<b>Abbildung 7:</b> Virtuelles Modell der Fibula eines Patienten mit individuell entworfenen Sägeschablonen _____	21
<b>Abbildung 8:</b> Virtuelles Modell des rekonstruierten Unterkiefers. Ansicht von rechts (A) und posterior (B) _____	21
<b>Abbildung 9:</b> (A) Präoperativer Zustand. (B) Virtuelles Modell des rekonstruierten Unterkiefers _____	22
<b>Abbildung 10:</b> Studiendesign _____	26
<b>Abbildung 11:</b> Schaltfläche der Thresholding-Funktion _____	32
<b>Abbildung 12:</b> Beispiel eines Schweineunterkiefers in axialer Schnittebene nach Thresholding (grünes Label) _____	33
<b>Abbildung 13:</b> Schaltfläche der Funktion "Multiple slice edit" _____	34
<b>Abbildung 14:</b> Schweineunterkiefer nach vorausgegangenem Thresholding (grüne Markierung) _____	34
<b>Abbildung 15:</b> Funktionsweise der Interpolier-Funktion im Programm Mimics Medical _____	35
<b>Abbildung 16:</b> Ansicht aller Schnittebenen und des 3D-Objekts nach abgeschlossener Segmentierung _____	36
<b>Abbildung 17:</b> Schaltfläche der Funktion "Dynamic Region Growing" mit beispielhaften Werten _____	37
<b>Abbildung 18:</b> Schweinekiefer nach vorausgegangenem Dynamic Region Growing (grünes Label) _____	38
<b>Abbildung 19:</b> ImFusion Labels. Zu sehen sind die DICOM-Unterordner nach dem Import _____	41
<b>Abbildung 20:</b> ImFusion Labels. Arbeitsumfeld unter "Annotation" mit allen Schnittebenen einer Schweinekiefer-CT inklusive eines vordefinierten 3D-Objekts _____	42
<b>Abbildung 21:</b> ImFusion Labels. Zu sehen ist das Bedienfeld zur Festlegung des Zielbereichs _____	43
<b>Abbildung 22:</b> ImFusion Labels. Bildschirmausschnitt der Schaltfläche während der Segmentierung („Interactive Segmentation“) _____	44
<b>Abbildung 23:</b> Skizze der Funktionsweise des Cursors in ImFusion Labels (Abstrakte Darstellung einer Knochen-Weichteil-Grenze) _____	45
<b>Abbildung 24:</b> ImFusion Labels. Axialer Schnitt. A) Setzen der Background-Markierungen; B) Setzen der Vordergrund-Markierungen (Label 1) _____	46
<b>Abbildung 25:</b> ImFusion Labels. Durch den automatisierten Algorithmus segmentierter Teil des Unterkiefers _____	47

<b>Abbildung 26:</b> ImFusion Labels. Übersicht in Annotation nach Segmentierung	48
<b>Abbildung 27:</b> ImFusion Suite. Übersicht nach Import der bearbeiteten Datei	49
<b>Abbildung 28:</b> ImFusion Suite. A) Bildausschnitt der Schaltfläche "Extract Mesh"; B) Bildausschnitt der Schaltfläche "Annotations"	49
<b>Abbildung 29:</b> Artec Studio 12. 3-Punkt-Alignment Verfahrens nach dem Setzen der Punkte	50
<b>Abbildung 30:</b> Artec Studio 12. Ergebnis des 3-Punkt-Alignments	51
<b>Abbildung 31:</b> A) Unterkieferhälfte nach Segmentierung einer CT-Datei; B) An den optischen Scan angepasste Maße des Unterkiefers in (A)	52
<b>Abbildung 32:</b> MeshLab. Ausgabe der Berechnungsergebnisse	54
<b>Abbildung 33:</b> MeshLab. Farbkarte der Oberflächenabweichung des segmentierten Unterkiefers im Vergleich zum optischen 3D-Scan	55
<b>Abbildung 34:</b> Vergleich der Segmentierungszeiten der korrespondierenden Modalitäten	60
<b>Abbildung 35:</b> Vergleich der Segmentierungszeiten der untersuchten Segmentierungsalgorithmen	60
<b>Abbildung 36:</b> Hausdorff Distance (HD) der geometrischen Abweichung der angewandten Algorithmen und Modalitäten	61
<b>Abbildung 37:</b> Mean Surface Distance (MSD) der geometrischen Abweichung der angewandten Algorithmen und Modalitäten	62
<b>Abbildung 38:</b> Root Mean Square Distance (RMSD) der geometrischen Abweichung der angewandten Algorithmen und Modalitäten	63
<b>Abbildung 39:</b> Bland-Altman-Plots zur Einschätzung der Übereinstimmung der Kombinationen aus den Segmentierungsalgorithmen und Modalitäten	64
<b>Abbildung 40:</b> Segmentierungszeit der eingesetzten Algorithmen und Modalitäten	65

## II. Tabellenverzeichnis

**Tabelle 1:** Gegenüberstellung der Modalitäten und Algorithmen hinsichtlich der geometrischen Abweichungen der Segmentierungsergebnisse von den optischen 3D-Scans der Schweinekiefer \_\_\_\_\_ 59

### III. Abkürzungsverzeichnis

CAD	Computer Aided Design
CAM	Computer Aided Manufacturing
CS	Compressed Sensing
CT	Computertomographie
DICOM	Digital Imaging and Communications in Medicine
FFF	Fibula Free Flap
FOV	Field of View
GV	Grayscale Value
HD	Hausdorff-Distance
HU	Hounsfield Units
ICC	Inter-/Intrarater-Korrelationskoeffizient
MKG	Mund-, Kiefer- und Gesichtschirurgie
MRT	Magnetresonanztomographie
MSD	Mean Surface Distance
RMSD	Root Mean Square Distance
ROI	Region of Interest
SENSE	Sensitivity Encoding
STL	Standard Tessellation Language
TE	Echo Time
TR	Repetition Time

# 1 Einleitung

In den letzten Jahren verbesserten sich die computerbasierte Behandlungsplanung und Erfolgsüberprüfung durchgeführter Operationen in der Mund-, Kiefer- und Gesichtschirurgie (MKG) erheblich (Mazzoni et al., 2010; Zinser et al., 2013). Aufgrund steigender Ansprüche an Präzision und damit an Sicherheit, Effektivität und Effizienz im Operationsablauf und der Nachbehandlung, vor allem im komplexen Gesichts- und Kieferbereich, ist die digitale Darstellung der individuellen Anatomie der Patientinnen und Patienten in Zukunft unentbehrlich (Orentlicher et al., 2010; Tucker et al., 2010). Dabei werden dreidimensionale Objekte der benötigten anatomischen Struktur, wie zum Beispiel des Unterkiefers, benötigt. Diese werden virtuell, mithilfe unterschiedlicher Bildgebungen, generiert. Die 3D-Objekte müssen dem Anspruch gerecht werden, ein möglichst genaues Abbild der realen Anatomie liefern zu können. Denn ungenaue virtuelle Modelle des Gesichtsbereichs, wie Stoor et al. (2014) zeigten, können zu intraoperativen Komplikationen und schlecht sitzenden Implantaten führen. Weiterhin kann davon ausgegangen werden, dass mit wachsendem Fortschritt im Bereich der virtuellen Behandlungsoptimierung und der damit zusammenhängenden Ausweitung des Einsatzgebietes innerhalb der MKG, immer genauere Oberflächenmodelle benötigt werden (van Eijnatten et al., 2018).

## 1.1 Segmentierung

Auf dem Weg von der Bildgebung des Unterkiefers bis hin zum 3D-Modell ist die Segmentierung einer der Hauptbestandteile und damit essenzielle Stellschraube zur Beeinflussung der Genauigkeit, Effektivität und Sicherheit der virtuellen Operationsplanung (Fourie et al., 2012; Qiu et al., 2018; van Eijnatten et al., 2018). Dazu werden zunächst *Digital Imaging and Communications in Medicine* (DICOM)-

Datensätze erstellt, meist in Form von CT-Aufnahmen, woraufhin diese segmentiert werden können (Huotilainen et al., 2014; van Eijnatten et al., 2018). Durch die Segmentierung können innerhalb des DICOM-Datensatzes liegende Informationen, wie Graustufen, Linien und Texturen, selektiert werden. Dies ermöglicht, gewünschte Bereiche der Bilddatei zu untergliedern, zu gruppieren und weiterzuverarbeiten (Fan et al., 2019; Wallner et al., 2018).

Das konkrete Ziel der Segmentierung ist es, den gegebenen DICOM-Datensatz in eine *Standard Tessellation Language* (STL)-Datei umzuwandeln. Dieses Dateiformat stellt für die Speicherung von virtuellen 3D-Objekten den Standard dar (Huotilainen et al., 2014; Wallner et al., 2019a).

Dabei kann man vor allem zwei Hauptkategorien unterscheiden:

1. Regionenbasierte Verfahren: Diese Segmentierungsverfahren suchen nach Regionen, die ein festgelegtes Homogenitätskriterium aufweisen.
2. Kantenbasierte Verfahren: Diese Segmentierungstechniken suchen nach Kanten zwischen den Bereichen, die sich in einem oder mehreren Kriterien unterscheiden (Rogowska, 2009).

Im Folgenden sollen die in dieser Studie angewandten Segmentierungsalgorithmen beschrieben werden.

### 1.1.1 Konventionelle Segmentierungsalgorithmen

#### 1.1.1.1 Thresholding

Das *Thresholding* (zu Deutsch: Schwellenwertverfahren) zählt zu den regionenbasierten Verfahren (Rogowska, 2009). Es stellt, mit anschließender händischer Nachbearbeitung, das gängigste Verfahren zur Segmentierung des Unterkiefers dar, wie eine Untersuchung von van Eijnatten et al. (2018) zeigt. Beim

*Thresholding* wird vorausgesetzt, dass jeder Pixel einen bestimmten Wert hat (Gonzalez & Woods, 2017). In der CT- und MRT-Bildgebung handelt es sich dabei um bestimmte Grauwerte oder Intensitäten, die, im Falle der Computertomographie (CT), als Hounsfield Units (HU) angegeben sind.

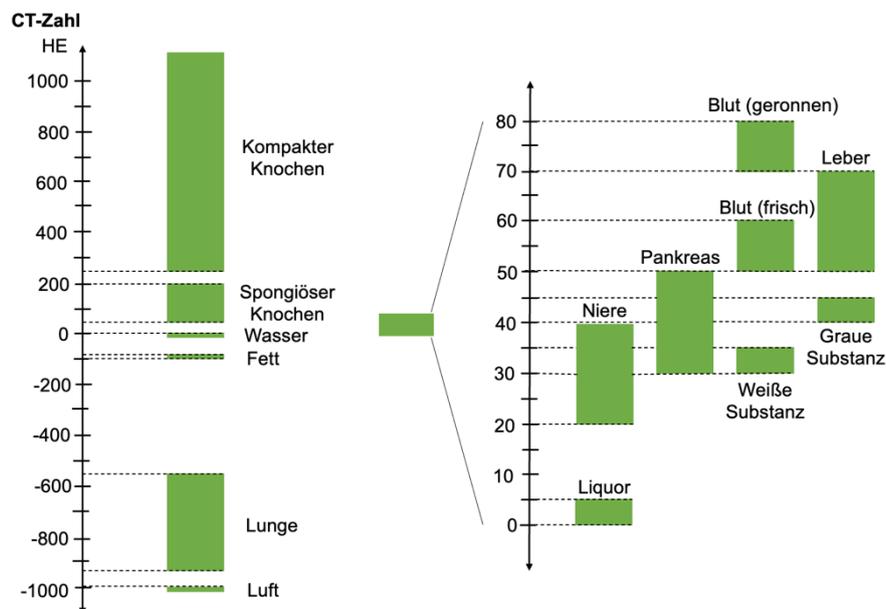


Abbildung 1: Hounsfield-Skala (in Anlehnung an *Abt. für Unterricht und Medien AUM, 2016*)

Abbildung 1 zeigt eine Hounsfield-Skala, die den Wertebereich für verschiedene Gewebe angibt. Zu sehen ist, dass der kompakte Knochen Werte ab 250 HU bis, je nach Dichte, über 1000 HU annehmen kann (Alcântara et al., 2019). Zur Verdeutlichung der Funktionsweise des Verfahrens, ist in Abbildung 2(A) ein Beispiel-Histogramm zu erkennen, das in erster Linie zeigt, wie viele Pixel von welcher Intensität im Bild enthalten sind. Zusätzlich ist auf der x-Achse mit einem „T“ markiert, wo der Schwellenwert für das Thresholding-Verfahren gelegt wurde. Alle Pixel, die eine Intensität unterhalb des Schwellenwerts T haben, werden beispielsweise als Hintergrund definiert, Pixel mit einer darüber liegenden Intensität dementsprechend als Objekt (Gonzalez & Woods, 2017; Rogowska, 2009). Ebenso ist es möglich, wie in Abbildung 2(B) zu sehen, zwei Schwellenwerte ( $T_1$  und  $T_2$ ), beziehungsweise einen

dazwischen liegenden Schwellenbereich, zu definieren. Nur die Pixel, die höhere Intensitäten als  $T_1$  und niedrigere Intensitäten als  $T_2$  aufweisen, werden zum Objekt gezählt (Gonzalez & Woods, 2017; Rogowska, 2009).

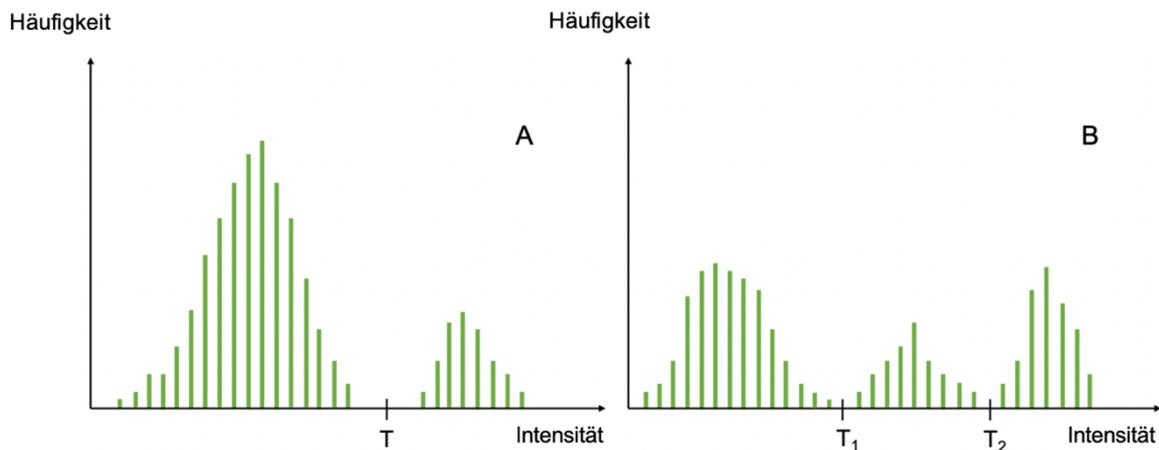


Abbildung 2: Histogramme zweier Beispielbilder

Wird nun, bei der Segmentierung eines Unterkiefers im CT-Bild, der Schwellenbereich konkret zwischen 250 HU und 1000 HU festgelegt, sollte der kompakte Knochen als Objekt definiert werden. So würden beispielsweise Wasser und Fett ( $HU < 250$ ) als Hintergrund identifiziert werden.

Bei den Segmentierungen des Unterkiefers von MRT-Daten verhält es sich sehr ähnlich, jedoch können die Grauwerte hier keine Normwerte wie die Hounsfield Units bei der Computertomographie annehmen. Da diese von diversen Parametern abhängen, nehmen die Grauwerte arbiträre, also willkürliche Werte an (Gerber & Peterson, 2008). Als Konsequenz für das *Thresholding* sollten die Schwellenwerte für jede einzelne MRT-Aufnahme angepasst werden, um gute Segmentierungsergebnisse zu liefern (Probst et al., 2021; van Eijnatten et al., 2016).

### 1.1.1.2 Region Growing

Eine weitere konventionelle Möglichkeit der regionenbasierten Segmentierung stellt das *Region Growing* dar. Während sich das Thresholding auf die Intensitäten der einzelnen Pixel konzentriert, wird beim *Region Growing* nach zusammenhängenden Gruppen von Pixeln mit ähnlicher Intensität gesucht. Hierzu müssen anfangs ein oder mehrere Seed-Points (zu Deutsch: Saatpunkte) festgelegt werden. Diese entsprechen vorher festgelegten Pixeln, die einen passenden Startpunkt für das *Region Growing* darstellen. Von diesen Punkten aus werden die benachbarten Pixel auf vorher festgelegte Parameter, beispielsweise einen bestimmten Grauwertebereich, überprüft. Wenn die Pixel den Vorgaben entsprechen, werden sie als Vordergrund definiert. Vom Seed-Point ausgehend wächst die Region, bis keine benachbarten Pixel mehr den Homogenitätskriterien entsprechen. Dadurch wird also nicht jeder Pixel, wie beim Thresholding-Verfahren, abgefragt, sondern nur diejenigen, die mit dem Seed-Point, beziehungsweise dessen nebenstehenden und als vordergründig markierten Pixeln benachbart sind (Gonzalez & Woods, 2017; Rogowska, 2009).

Dieses Segmentierungsverfahren wurde bereits erfolgreich an CT- und MRT-Daten verschiedener Gewebe angewandt (Norouzi et al., 2014; Pan & Lu, 2007; Pohle & Toennies, 2001). Zur Verdeutlichung der Arbeitsweise des Algorithmus zeigt die

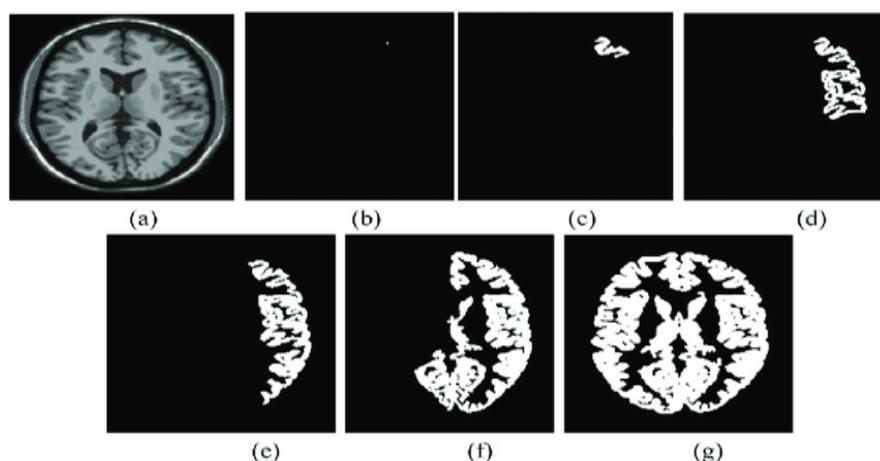


Abbildung 3: Skizze des Region Growing Prozesses (Imdad et al., 2019)

Abbildung 3 den groben Ablauf des *Region Growings*. In Bildabschnitt (a) zeigt sich ein beispielhaftes axiales Schnittbild des Schädels. Nachdem ein Seed Point ausgewählt wurde (b, weißer Punkt), erweitert sich der Region Growing Prozess um sämtliche Nachbarpixel (c-g), sodass in Bildabschnitt (g) alle benachbarten Pixel miteinander verbunden werden.

#### 1.1.1.3 Händische Nachbearbeitung

Trotz dieser etablierten Algorithmen bleiben nach dem Segmentierungsprozess oft Fehler und residuale Löcher, beziehungsweise unvollständig segmentierte Objekte, die durch händische Nacharbeit korrigiert und vervollständigt werden müssen. Dieser Umstand kann durch eventuelle Pathologien der Patientinnen und Patienten oder iatrogen eingebrachtes Fremdmaterial zusätzlich erschwert werden (Olabarriaga & Smeulders, 2001). Eine solche Nachbearbeitung fällt zeitlich vor allem bei der oft fehlerhaften Segmentierung des kortikalen Knochens im MRT-Bild ins Gewicht (Pan & Lu, 2007; Probst et al., 2021).

Diese semiautomatischen Verfahren, besonders bezogen auf die händische Nachbearbeitung der Segmentierung, sind immer noch zeitraubend. Zusätzlich unterliegen sie einer relativ großen Schwankung, konkret einer resultierenden hohen Intra- und Interrater-Variabilität (Olabarriaga & Smeulders, 2001; Rajapakse & Kruggel, 1998). Vor allem der zeitliche Faktor beansprucht die Anwenderin oder den Anwender im klinischen Alltag oft zusätzlich, was wiederum negativen Einfluss auf die Behandlungsplanung und die damit verbundenen Kosten haben kann (Qiu et al., 2019; Rengier et al., 2010; van Eijnatten et al., 2018).

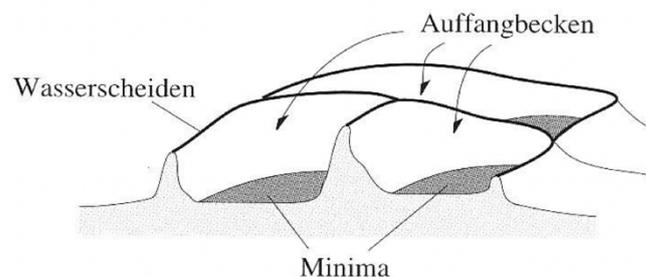
## 1.1.2 Automatisierte/Interaktive Segmentierungsalgorithmen

Als zeitgemäße Bestrebung liegt es nahe, diese Aufgabe immer mehr zu automatisieren, die Anwendung zu erleichtern und idealerweise die Genauigkeit der Ergebnisse und die Geschwindigkeit der Segmentierung zu verbessern.

Neue Ansätze sind automatisierte, interaktive Verfahren, die auf der Watershed-Segmentierung und der Random-Walker-Segmentierung basieren. Diese können im Rahmen des Algorithmus automatisch, nach der Festlegung gewisser Parameter und der entsprechenden Startpunkte, ablaufen. Dies soll im Folgenden kurz erläutert werden.

### 1.1.2.1 Watershed-Segmentierung

Die Grundidee der Watershed-Segmentierung (zu Deutsch: Wasserscheiden-Segmentierung) ist, dass ein Bild als topographische Landschaft betrachtet wird.



*Abbildung 4: Funktionsweise der Wasserscheidentransformation (Sugg, 2005)*

Beispielsweise stellen Pixel mit höheren Grauwerten Erhöhungen oder Berge dar und Pixel mit niedrigen Grauwerten fungieren als Täler. Zusätzlich teilt die Watershed-Segmentierung die so entstandene Darstellung in Auffangbecken ein. Diese Becken umfassen für jedes Minimum alle Punkte, deren Weg des steilsten Abstiegs an diesem Minimum endet. Wasserscheiden beziehungsweise Maxima trennen diese Becken

voneinander (siehe Abbildung 4). Damit wird jeder Pixel einer Region oder einer Wasserscheide zugeordnet (Preim & Botha, 2013; Rogowska, 2009).

Um korrespondierende Regionen für die Segmentierung zu kombinieren, müssen die Auffangbecken so lange geflutet werden, bis sich der Wasserspiegel über die gewünschte Wasserscheide, also über eine bestimmte Pixelintensität, hebt (Preim & Botha, 2013; Rogowska, 2009).

Um nun gezielt die Bereiche eines Bildes zu fluten, die von Interesse sind, kann das Marker-basierte Verfahren angewendet werden. So kann, durch Markierung des Vordergrunds und des Hintergrunds, spezifiziert werden, wo das Zielobjekt liegt. So wird eine virtuelle Grenze zwischen Hintergrund-Region und Objekt gezogen (Preim & Botha, 2013; Rogowska, 2009).

### 1.1.2.2 Random-Walker-Segmentierung

Zum Startpunkt der Random-Walker-Segmentierung werden vom Benutzer Seed-Points (Startpunkte) festgelegt, die verschiedene Regionen (Label) repräsentieren, wie

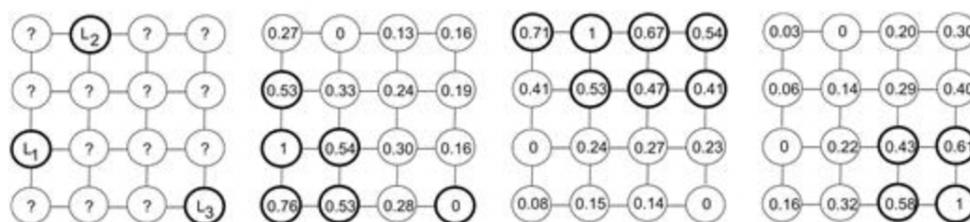


Abbildung 5: Skizze des Random-Walker-Algorithmus (Preim & Botha, 2013)

zum Beispiel den Hintergrund oder das gesuchte Objekt. Daraufhin wird vom Algorithmus für jeden Pixel die Wahrscheinlichkeit berechnet, dass ein Random Walker die jeweiligen Seed-Points erreicht. Demzufolge wird jeder Pixel dem Label zugeteilt, das durch den Seed-Point repräsentiert wird, welcher am wahrscheinlichsten erreicht wird. Am Beispiel der Abbildung 5 wurden die jeweiligen Seed-Points (L<sub>1-3</sub>) der Label gesetzt. Die weiteren Bilder von links nach rechts geben die Wahrscheinlichkeit

für jedes Pixel an, L1, L2 und L3 zu erreichen. Der dicke Kreis stellt jeweils dar, welches Label die höchste Wahrscheinlichkeit für jedes Pixel hat (Grady, 2006; Preim & Botha, 2013).

Für die Segmentierung des Unterkiefers mithilfe der neuen Algorithmen gibt es bisher wenig Evidenz. Jedoch konnte speziell die Anwendung auf die MRT-Bildgebung anderer anatomischer Regionen dokumentiert werden. Es konnte durch McGrath et al. (2020) gezeigt werden, dass die Anwendung der neuen Ansatzpunkte schneller und weniger beanspruchend als eine händische Segmentierung sein kann. Gleichzeitig war die Genauigkeit der Segmentierungen etwas höher als die händische Segmentierung (McGrath et al., 2020).

## 1.2 CAD/CAM-Chirurgie

### 1.2.1 Grundlagen der CAD/CAM-Chirurgie

Die durch Segmentierung extrahierten Bereiche der Bilddatei können als 3D-Objekt in Form einer STL-Datei abgespeichert werden. Danach ist es möglich, diese 3D-Objekte, hier in Form des knöchernen Unterkiefers, zu nutzen, um beispielsweise den Unterkiefer virtuell zu rekonstruieren, gewisse OP-Schritte zu simulieren, Geometrien für den 3D-Druck zu erstellen und damit der CAD/CAM-Chirurgie (Computer Aided Design/Computer Aided Manufacturing-Chirurgie) zugänglich zu machen (Badiali et al., 2014; Huff et al., 2018; Ritschl et al., 2017b).

Die CAD/CAM-Chirurgie bietet, wie unter anderem von Ritschl et al. (2017b) bereits beschrieben, dabei einige Vorteile im Vergleich zur konventionellen Chirurgie des Unterkiefers. Durch sie können nicht nur die Operationszeit und der Krankenhausaufenthalt verkürzt werden, sondern auch die Genauigkeit der

Rekonstruktion des Unterkiefers (Sieira Gil et al., 2015) sowie die Knochenkonsolidierung und die daraus resultierende Stabilität verbessert werden (Avraham et al., 2014; Weitz et al., 2016). Zusätzlich konnte durch den Einsatz CAD/CAM-assistierter Chirurgie das morphologische Ergebnis nach Unterkieferrekonstruktionen optimiert werden (Tarsitano et al., 2016) und ein mindestens gleichbleibendes funktionelles Outcome im Vergleich zu konventionellen Operationsverfahren gezeigt werden (Ritschl et al., 2017a). Darüber hinaus wurde dokumentiert, dass die Interrater-Variabilität zwischen Operierenden nach virtueller Planung geringer ausfiel (Avraham et al., 2014; Ritschl et al., 2017b).

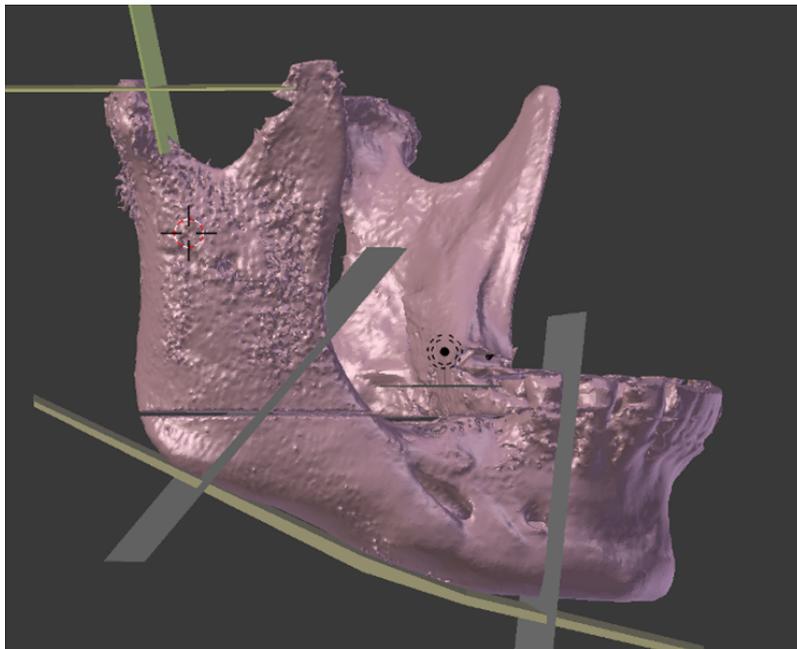
Dennoch sind auch Nachteile des CAD/CAM-Verfahrens in der Mund-, Kiefer- und Gesichtschirurgie auszumachen, wie Ritschl et al. (2017b) gleichermaßen erläuterten. Diese liegen vor allem in der nötigen, teilweise exzessiven präoperativen Planung, die wiederum mit einem erwähnenswerten Zeit- und Personalaufwand verbunden ist. Einhergehend mit dieser Planung ist, dass ein gewisser intraoperativer Verlust der Flexibilität akzeptiert werden muss, da die einzelnen Operationsschritte bereits virtuell geplant, teilweise mehrfach geübt und einzelne Operationswerkzeuge individuell hergestellt wurden. Folglich kann auf unerwartete Ereignisse teilweise weniger dynamisch reagiert werden (Moro et al., 2009; Ritschl et al., 2017b). Durch beispielsweise Voroperationen, die bei großem zeitlichem Abstand zwischen der Bildgebung mit folgender virtueller Planung und der eigentlichen Operation stattfinden, kann die Anatomie der Betroffenen deutlich verändert sein. Dies kann zur Folge haben, dass Schablonen zur Schnittführung oder vorbereitete Platten nicht mehr genutzt werden können (Avraham et al., 2014; Hanken et al., 2015; Moro et al., 2009). Nicht zu vernachlässigen ist auch der hohe finanzielle Aufwand, den die Computer-assistierte Chirurgie mit sich bringen kann. So haben Rommel et al. (2017) die Mehrkosten für die individuelle Operationsplanung und Schablonenherstellung, die

von Herstellern von Osteosynthese-Material angeboten werden, pro Fall mit 2250 € berechnet (Ritschl et al., 2021a; Rommel et al., 2017). Mittlerweile können diese Zusatzkosten, wie beispielsweise von Ritschl et al. (2021a) beschrieben, durch kosteneffiziente, hausinterne Operationsplanung und -Materialherstellung im Median auf 14,30 €, bezogen auf die Materialkosten, gesenkt werden (Ritschl et al., 2021a). Moe et al. (2021) kalkulierten 3,78 US-Dollar, Dell'Aversana Orabona et al. (2018) berechneten lediglich 3 € pro Patientenfall (Dell'Aversana Orabona et al., 2018; Moe et al., 2021; Ritschl et al., 2021a). Somit besteht inzwischen die Möglichkeit, die entstehenden Mehrkosten durch virtuelle Operationsplanung erheblich zu reduzieren und nicht zuletzt durch die resultierenden Zeitersparnisse in der Patientenversorgung zu egalisieren. Zusätzlich unterliegt das Feld der CAD/CAM-Chirurgie einer ständigen Forschung und Entwicklung, welche jeden Teilschritt, von der Bildgebung über die Bildverarbeitung bis hin zur Behandlung der Erkrankten, betrifft. Dies reduziert die nötigen Investitionen in diesem Bereich weiterhin Schritt für Schritt (Avraham et al., 2014; Hanken et al., 2015; Ritschl et al., 2017b). Zusammenfassend hat die CAD/CAM-Chirurgie also das Potential, die Behandlungskosten und -dauer zu reduzieren, aber auch das klinische Personal und die Patientinnen und Patienten zu entlasten und den Behandlungserfolg zu maximieren.

### 1.2.2 Unterkieferrekonstruktion als Anwendungsbeispiel der CAD/CAM-Chirurgie

Eine bereits gängige, jedoch schwerwiegende Operation im Bereich der MKG-Chirurgie ist die Unterkieferrekonstruktion nach chirurgischer Teil- oder Kontinuitätsresektion, besonders nach der Einführung des freien Fibulalappens zur Unterkieferrekonstruktion (FFF) durch Hidalgo (1989).

Ein wirklicher Quantensprung im rekonstruktiven Bereich war die Einführung der CAD/CAM-Chirurgie in diesem operativen Feld (Ritschl et al., 2021b). Eben genannte soll anhand der beispielhaften virtuellen Planung des FFF im Folgenden kurz skizziert werden.



*Abbildung 6: Virtuelle Planung der Schnittführung am bereits segmentierten Unterkiefer eines Patienten*

Zunächst wird der Unterkiefer individuell segmentiert und als 3D-Modell abgespeichert. Anhand dessen kann zuerst die Resektionsplanung stattfinden, die dem Behandelnden intraoperativ genau anzeigt, wo die Schnitte zur Unterkieferresektion verlaufen sollen (siehe Abbildung 6) (Foley et al., 2013; Hirsch et al., 2009; Roser et al., 2010).



Abbildung 7: Virtuelles Modell der Fibula eines Patienten mit individuell entworfenen Sägeschablonen

Daraufhin wird die Bildgebung der Fibula des Patienten ebenfalls zu einem virtuellen 3D-Modell umgewandelt. Mithilfe dieser kann, analog zum Unterkiefer, geplant werden, wie die benötigten Fibulasegmente aussehen sollen. Demzufolge werden nun Sägeschablonen entwickelt, die der Operateurin oder dem Operateur während des Eingriffs exakt anzeigen, wo und in welchem Winkel die benötigten Fibulasegmente entnommen werden müssen. Dies ist nötig, um die im Vorfeld geplante Rekonstruktion des Unterkiefers auf die Anatomie der Patientin oder des Patienten bestmöglich

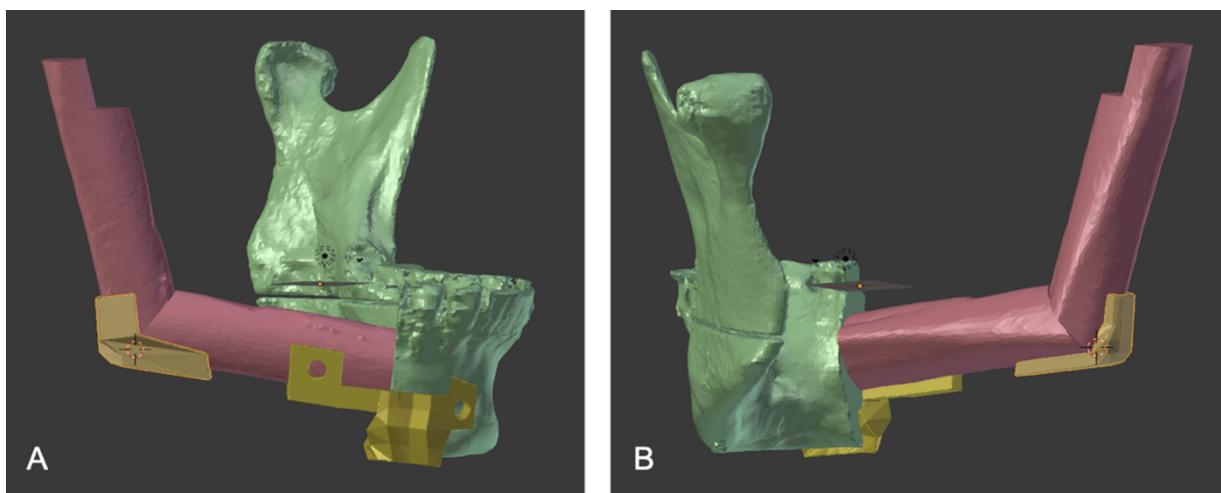


Abbildung 8: Virtuelles Modell des rekonstruierten Unterkiefers. Ansicht von rechts (A) und posterior (B)

anzupassen (siehe Abbildung 7) (Antony et al., 2011; Hirsch et al., 2009; Roser et al., 2010).

Die geplanten Fibulasegmente können nun virtuell so zusammengesetzt werden, dass sie den Defekt im Unterkiefer funktional und möglichst anatoforn auffüllen (Antony et al., 2011; Hirsch et al., 2009; Roser et al., 2010). Wie in Abbildung 8 beispielhaft zu sehen, wurden zwei der drei Fibulasegmente (rot) angebracht und mit Osteosynthesematerial (gelb) virtuell fixiert.

Intraoperativ können die Fibulasegmente wie geplant zusammengesetzt und mit dem Kiefer verbunden werden. Hierzu dient im Vorfeld geplantes, individuelles und winkelstabiles Osteosynthesematerial. Nach mikrochirurgischer Anastomosierung der versorgenden Gefäße kann die Operation beendet werden. Das Ziel ist ein morphologisches und funktionales Ergebnis, das möglichst nah an die ursprüngliche individuelle Anatomie heranreicht (Antony et al., 2011; Foley et al., 2013; Hirsch et al., 2009). Dies ist essentiell, da eine passende Übereinstimmung des rekonstruierten Unterkiefers mit dem Oberkiefer Voraussetzung für eine bestmögliche dentale Wiederherstellung ist (Hayden et al., 2012). Wie in Abbildung 9 zu sehen, kann ein weiteres Fibulasegment angepasst und integriert werden. In Abbildungsteil (A) ist der

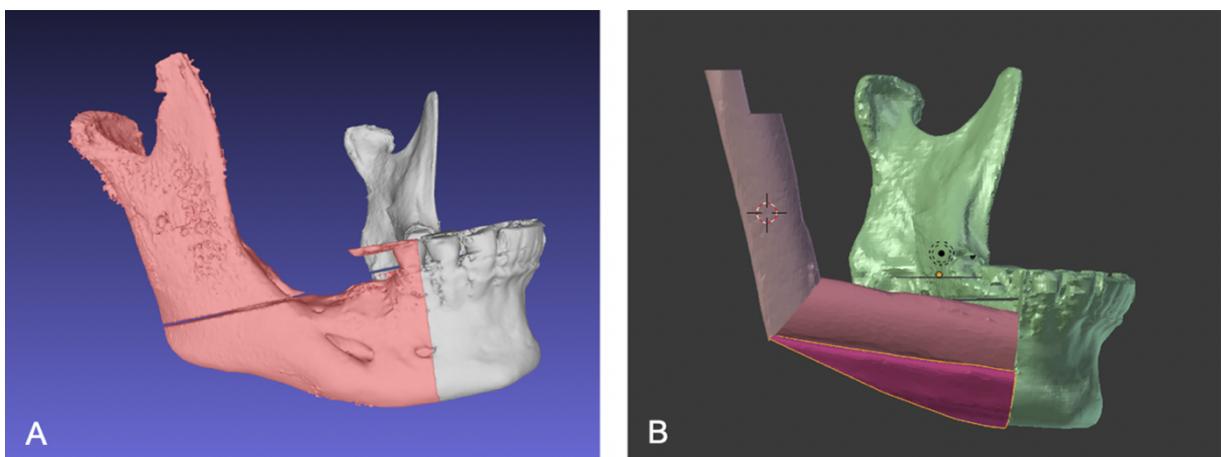


Abbildung 9: (A) Präoperativer Zustand. (B) Virtuelles Modell des rekonstruierten Unterkiefers

präoperative Zustand eines Unterkiefers mit dem zu resezierenden Anteil (rot) gezeigt. Abbildungsteil (B) stellt den rekonstruierten Unterkiefer nach Integration aller geplanten Fibulasegmente dar. Wie eine Untersuchung von He et al. (2011) zeigt, kann die hier angewandte „Double-Barrel“-Technik nicht nur die Höhe des rekonstruierten Unterkiefers an die des präoperativen Zustands angleichen und damit das morphologische Ergebnis verbessern, sondern erlaubt dadurch auch eine dentale Osseointegration von Implantaten und optimiert so die dentale Rehabilitation (He et al., 2011).

### 1.2.3 Bildgebung in der CAD/CAM-Chirurgie

Der derzeitige Standard in der Bildgebung für virtuelle Operationsplanung im Bereich der Mund-, Kiefer- und Gesichtschirurgie ist vor allem die Computertomographie, was nicht zuletzt an der guten Darstellung knöcherner Strukturen liegt (Qiu et al., 2018; Wallner et al., 2019a). Bei Betrachtung des potentiellen Schadens, den die ionisierende Strahlung anrichten kann, wie beispielsweise eine erhöhte Wahrscheinlichkeit, Schilddrüsenkarzinome nach Exposition mit diagnostischer Röntgenstrahlung zu entwickeln (Han & Kim, 2018), ist die Betrachtung der Magnetresonanztomographie (MRT) sinnvoll. Hier konnte bereits gezeigt werden, dass sie nicht nur zur guten Weichteildarstellung dienen kann, sondern durchaus auch zur Knochen- und Zahndarstellung (Mastrogiacono et al., 2019). Dies gilt vor allem, wenn die Geräteeinstellung an die Gegebenheiten der Mund-, Kiefer- und Gesichtschirurgie angepasst wurde, beispielsweise durch entsprechende Sequenzen und geeignete Spulen (Assaf et al., 2014; Hilgenfeld et al., 2017; Prager et al., 2015). Ebenso konnte zum einen gezeigt werden, dass die MRT im Vergleich zur CT sehr gute Ergebnisse liefern kann, wenn es darum geht, genaue Darstellungen und

vergleichbare Abmessungen des Unterkiefers zu liefern (Duttenhoefer et al., 2015). Zum anderen stellte sich heraus, dass MRT-Bilder des Unterkiefers dazu geeignet sind, durch Segmentierung, in 3D-Objekte (STL-Daten) umgewandelt zu werden und für den weiteren Gebrauch, im Sinne der CAD/CAM-Chirurgie genutzt zu werden (Probst et al., 2021; van Eijnatten et al., 2016).

## 2 Zielsetzung

Da die CAD/CAM-Technik den Status Quo der modernen MKG-Chirurgie darstellt und diese einen immer höheren Stellenwert innerhalb des Fachgebiets einnimmt, ist es nötig, die Bausteine der virtuellen Operationsplanung weiterhin zu optimieren.

Ziel dieser Studie ist es zu untersuchen, ob ein interaktiver, automatisierter Segmentierungsalgorithmus in der Lage ist, im Vergleich zu der etablierten semiautomatischen, beziehungsweise händischen Methode, gleichwertige Ergebnisse zu liefern. Dies soll auf Basis von CT- sowie MRT-DICOM Datensätzen von 5 Schweineunterkiefen geschehen, um die Umsetzbarkeit und Genauigkeit der Segmentierungen anhand beider Modalitäten zusätzlich zu vergleichen.

Weiterhin ist es das Ziel, die investierte Zeit in die Segmentierung der gegebenen Schweinekiefer zu ermitteln, um eventuelle zeitliche Unterschiede zwischen den Segmentierungsalgorithmen und den Modalitäten CT und MRT festzustellen.

Schließlich soll auch, mithilfe von Intra- und Interpersonalanalysen (ICC), gezeigt werden, wie sehr sich die Segmentierungsergebnisse erstens zwischen zwei verschiedenen Anwendern, zweitens innerhalb eines Anwenders, unterscheiden.

Zusammenfassend liegt der Fokus auf dem Vorhaben, die Reliabilität, Validität und Objektivität der Unterkiefersegmentierung als Teil der CAD/CAM-Chirurgie weiter zu verbessern. Es ist also von Interesse, ob der interaktive, automatisierte Segmentierungsalgorithmus von *ImFusion* in der Lage ist, an den etablierten, semiautomatischen Unterkiefersegmentierungsalgorithmus heranzureichen und diesen unter Umständen sogar zu übertreffen. Dies soll durch die Punkte Genauigkeit und Zeitersparnis quantifiziert werden. Zusätzlich sollen die Option der Segmentierung der MRT-Aufnahmen des Unterkiefers und das Zusammenspiel mit dem automatisierten Algorithmus getestet werden.

### 3 Material und Methoden

#### 3.1 Ethikvotum und Tierschutz

Da es sich bei dieser Studie um die Untersuchung von Schweinekadavern handelte, die bereits unabhängig von der Studie geschlachtet wurden, war keine Genehmigung durch die Ethikkommission der Technischen Universität München, des Klinikums rechts der Isar oder durch die Regierung von Oberbayern erforderlich.

#### 3.2 Studiendesign

Diese Studie wurde mithilfe der von Probst et al. (2021) bereitgestellten CT- und MRT-Daten sowie der angefertigten optischen Scans der Schweineunterkieferhälften (n=10) geplant und durchgeführt. Dementsprechend lehnen sich die Beschreibung der Materialgewinnung und das Studiendesign an die Erläuterungen von Probst et al.

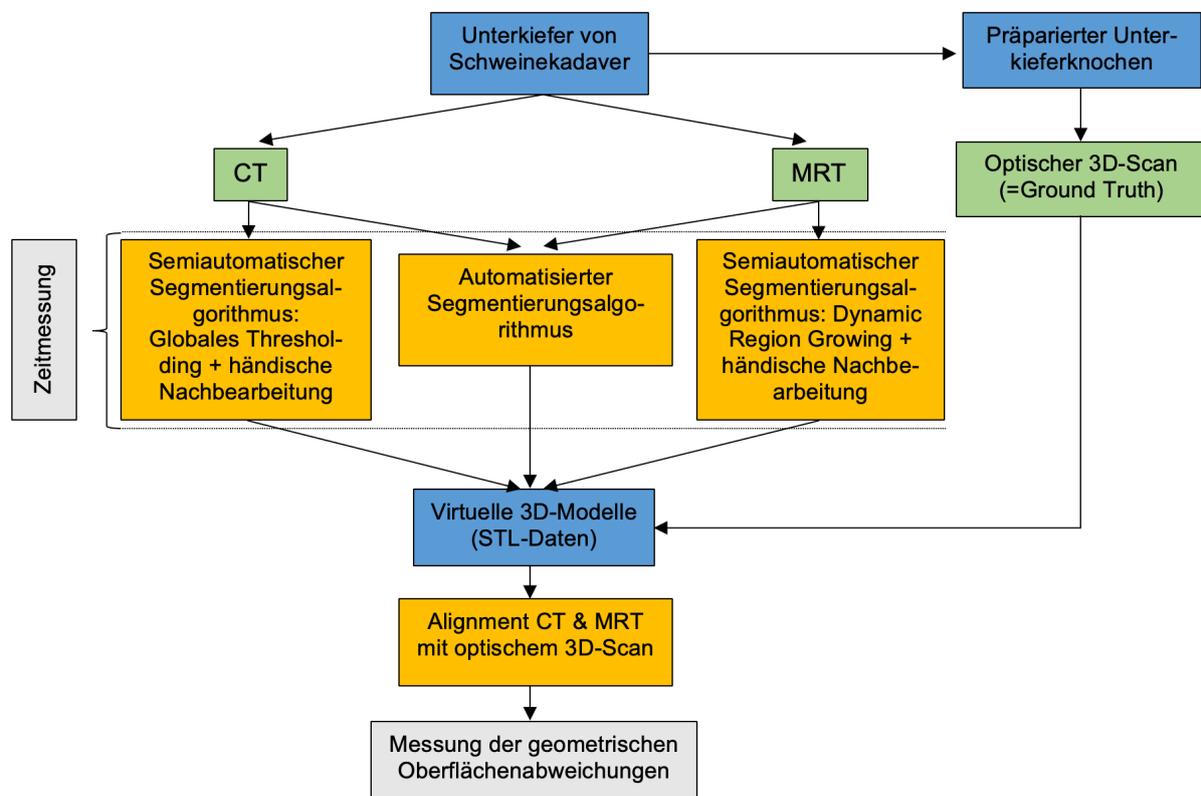


Abbildung 10: Studiendesign

(2021) an. Wie in Abbildung 10 zu sehen ist, wurden anhand der DICOM-Daten der CT und MRT zunächst die Unterkiefer vom umgebenden Weichteilgewebe segmentiert und als STL-Dateien, also als virtuelle 3D-Objekte, abgespeichert.

Hierbei wurde jeweils nur eine, also zunächst die rechte, dann die linke Unterkieferhälfte der entsprechenden Schweinekiefer segmentiert. Die Segmentierung wurde zum einen mithilfe eines semiautomatischen Algorithmus und zum anderen durch einen automatisierten Algorithmus, anhand von CT- und MRT-Aufnahmen angefertigt. Der Segmentierungsprozess wurde jeweils von zwei Untersuchern, je zweimal pro Segmentierungsalgorithmus und Modalität, unabhängig zueinander durchgeführt.

Die erstellten 3D-Objekte der Unterkieferhälften konnten nun mit korrespondierenden optischen Scans (=Ground Truth) verglichen werden, indem sie per Alignment digital übereinandergelegt wurden. Nach entsprechender Nachbearbeitung konnte der ausgewählte Teil des segmentierten Unterkiefers hinsichtlich bestimmter Parameter auf geometrische Unterschiede der Oberfläche mit dem optischen Scan untersucht werden.

Um zusätzlich die zeitliche Komponente der Segmentierungen zu untersuchen, wurde die benötigte Zeit festgehalten, um die jeweiligen Unterkieferhälften zu segmentieren, also um die gegebene DICOM-Datei in eine STL-Datei (3D-Objekt) umzuwandeln.

### 3.3 Material

Im Folgenden soll dargestellt werden, wie die bereitgestellten CT- und MRT-Datensätze der Schweineunterkiefer sowie die optischen 3D-Scans generiert wurden. Zusätzlich werden die verwendeten Materialien und Programme vorgestellt.

### 3.3.1 CT-Bildgebung

Die Schweineunterkiefer, inklusive des umgebenden Weichteilgewebes, wurden mit der Okklusionsebene horizontal zum Boden ausgerichtet. Anschließend wurden, mittels eines Philips Ingenuity 128-Geräts (Philips Healthcare, Best, Niederlande), die Mehrschicht-CT-Aufnahmen mit folgenden Parametern erstellt:

- Isotrope Voxelgröße: 0,67 mm
- Sichtfeld (FOV): 20-20 cm
- Röhrenspannung: 120 kV
- Röhrenstrom-Zeit-Produkt: 250 mAs (Probst et al., 2021)

### 3.3.2 MRT-Bildgebung

Wie bereits von Probst et al. (2021) beschrieben, wurden die Unterkiefer der Schweinekadaver in eine Wanne gelegt, die mit Wasser befüllt wurde. Die Okklusionsebene wurde ungefähr horizontal zum Boden ausgerichtet und eine 16-Kanal Kopf-Halsspule wurde um die Box gelegt. Die 3D T1- gewichtete MRT-Sequenz wurde mithilfe eines 3T-MRT-Systems (Elition, Philips Healthcare; Best, Niederlande) generiert. Diese Sequenz ist für die Knochenvisualisierung optimiert und bereits in klinischem Gebrauch (Probst et al., 2020). Zusätzlich wurde, um die Echozeit zu reduzieren, eine partielle Fourier-Bildgebung in Richtung der Frequenzcodierung mit dem Faktor von 60% angewandt (Gersing et al., 2018). Folgende Parameter galten für die Aufnahmen:

- Erfassungszeit: 03:08 min
- Sichtfeld (FOV): 180 mm
- Matrix: 420 x 419
- Erfasste Voxelgröße: 0,6 x 0,6 x 0,6 mm<sup>3</sup>

- Number of signal averages: 1
- Repetitionszeit (TR): 10 ms
- Echozeit (TE): 1,55 ms
- Compressed sensing (CS) + sensitivity encoding (SENSE): ja
- Reduktionsfaktor: 2,3 (Probst et al., 2021)

### 3.3.3 Optische 3D-Scans der Schweinekiefer

Nach der Anfertigung der CT- und MRT-Aufnahmen wurde, wie Probst et al. (2021) erklären, sämtliches Weichteilgewebe vom Unterkieferknochen entfernt, um einen optischen dreidimensionalen Scan der Unterkiefer zu schaffen. Diese Scans dienen als Referenz (=Ground Truth) (van Eijnatten et al., 2018).

Die Kadaver wurden lediglich mit herkömmlichen Sezierbesteck präpariert. Weder thermische noch chemische Behandlungen wurden am Knochen angewandt, um mögliche Schäden an der Knochenoberfläche zu vermeiden und das Ergebnis der geometrischen Oberflächenvergleiche nicht zu verfälschen (Gelaude et al., 2008; Van den Broeck et al., 2014).

Um nun dreidimensionale Bilder der Kieferknochenoberfläche zu erstellen, wurde ein optischer 3D-Scanner (Artec Space Spider, Artec 3D; Luxemburg) verwendet. Der Hersteller des Geräts gibt eine Auflösung bis 0,1 mm sowie eine Punktgenauigkeit bis 0,05 mm an. Durch die so generierten Daten wurden mithilfe der passenden Software (Artec Studio 14, Artec 3D; Luxemburg) und des zugehörigen Autopilot-Tools letztlich dreidimensionale Scans generiert. Um diese als Ground Truth zu nutzen und diese mit den Segmentierungsergebnissen vergleichen zu können, wurden sie als STL-Datei exportiert (Probst et al., 2021).

### 3.3.4 Verwendete Computer und Programme

Der verwendete Computer, der zur semiautomatischen Segmentierung genutzt wurde, hatte das Betriebssystem Windows 8 Professional Edition mit dem Prozessor Intel® Core i7-4770 (CPU @ 3.40 GHz, RAM 16 GB). Dieser befand sich in der Klinik für Mund-, Kiefer- und Gesichtschirurgie am Klinikum rechts der Isar. Der zweite verwendete Computer, der zur automatisierten Segmentierung herangezogen wurde, war mit dem Betriebssystem Windows 10 Professional Edition mit dem Prozessor Intel® Core i7-9700 CPU 3.60 GHz, RAM 32 GB) ausgestattet und befand sich in der Firma Kumovis (Trimburgstraße 2, 81249 München). Die verwendete Software wird im Folgenden aufgelistet:

- Mimics Medical 17.0 (Materialise, Belgien)
- ImFusion Labels und Suite (Version 2.19.2) (ImFusion, Deutschland)
- MeshLab 2021.07 (Open Source-Software)
- Artec Studio Professional 12 (Artec 3D, Luxemburg)
- Blender (Version 2.82a) (Open Source-Software)

## 3.4 Methoden

Um nun die DICOM-Daten in STL-Dateien umzuwandeln, also aus den CT- und MRT-Aufnahmen 3D-Modelle zu erstellen, wurden die Unterkiefer jeweils von zwei Anwendern segmentiert. Dabei wurde bei beiden verwendeten Modalitäten (CT und MRT) jeweils der semiautomatische und der automatisierte Segmentierungsalgorithmus genutzt. Um die Interrater- und Intrarater-Variabilität, genauer gesagt den Interrater- und Intrarater-Korrelationskoeffizienten (ICC), zu berechnen, wurde nach mindestens 6-wöchigem Abstand erneut segmentiert (Probst et al., 2021).

### 3.4.1 Zeitmessung

Um zu vergleichen, inwiefern sich die Segmentierungen zwischen den Modalitäten und den angewendeten Algorithmen zeitlich unterscheiden, wurde die benötigte Zeit der einzelnen Segmentierungen festgehalten. Der genaue Start- und Endpunkt der Zeitmessung wird bei der Beschreibung der Segmentierungsalgorithmen genannt.

### 3.4.2 Semiautomatischer Segmentierungsalgorithmus

Zunächst wurden die Segmentierungen mit dem Programm *Mimics Medical 17.0* (Materialise, Belgien) durchgeführt. Hierbei wurde der heutzutage gängigste semiautomatische Algorithmus eingesetzt.

Da sich der Arbeitsablauf für diesen Algorithmus für beide Modalitäten unterschied, werden sie getrennt voneinander erklärt.

#### 3.4.2.1 Arbeitsschritte CT

Zuerst wird der Ablauf der Segmentierungen der CT-Aufnahmen mithilfe des semiautomatischen Algorithmus geschildert.

##### 3.4.2.1.1 Segmentierung vorbereiten / Datei öffnen und Schnittbild ausrichten

Nach dem Öffnen des Programms *Mimics Medical* wurde der DICOM-Datensatz mit der CT-Aufnahme des gewünschten Schweinekiefers unter „New project wizard“ geöffnet. Nach der Angabe „CT compressed“ und der Auswahl des passenden Unterordners wurden die Lagebeziehungen der Aufnahme mit den Bezeichnungen „Top“ oder „Bottom“ im koronaren Schnittbild, mit „Anterior“ oder „Posterior“ im axialen Schnittbild und mit „Left“ oder „Right“ (in allen Schnittrichtungen möglich) festgelegt. Dies war für die korrekte Ausrichtung der Schnittebenen notwendig. Direkt danach wurde die Zeitmessung gestartet.

### 3.4.2.1.2 Thresholding und Festlegen des Zielbereichs

Zu Beginn der Segmentierung mithilfe des semiautomatischen Algorithmus wurde die Funktion „Thresholding“ verwendet. Dazu öffnete sich eine gleichnamige Schaltfläche (siehe Abbildung 11).

Da hier das Knochengewebe des Unterkiefers von Interesse war, wurde auf die Voreinstellung „Bone CT“ zurückgegriffen, welche einen passenden Bereich auf einer Grauwert-Skala (1250 bis 4095; entspricht einem Bereich von 226 bis 3071 HU) angab.

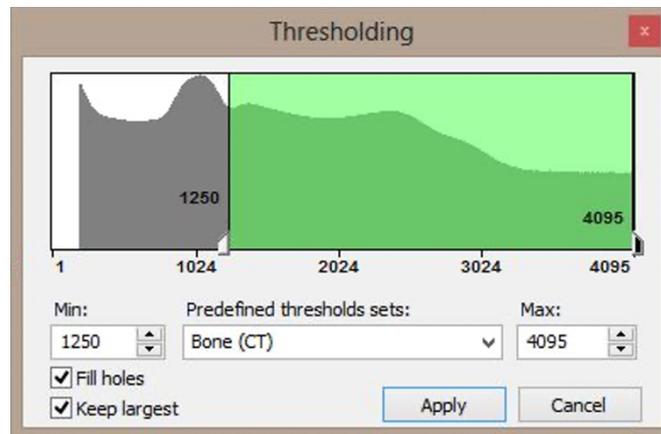


Abbildung 11: Schaltfläche der Thresholding-Funktion

Dieser Bereich hat sich als geeignet erwiesen, den kompakten Knochen gut darzustellen. Zusätzlich wurden die Punkte „Fill cavities“ und „Keep largest“ angewählt. „Fill cavities“ diente dazu, kleinere Löcher innerhalb des Knochens zu schließen. Die Funktion „Keep largest“ hatte den Effekt, ausschließlich das größte zusammenhängende Objekt zu behalten, das durch das *Thresholding* markiert wurde. Ein Beispiel einer CT eines Schweineunterkiefers nach Segmentierung durch die Funktion „Thresholding“ ist in Abbildung 12 gezeigt. Hier ist als grünes Label dargestellt, was durch das *Thresholding* als kompakter Knochen identifiziert wurde, beziehungsweise, was innerhalb des ausgewählten Schwellenbereichs lag. Daran

schloss sich das Festlegen des Zielbereichs an. Durch die Funktion „Crop Mask“, unter dem Reiter „Segmentation“, konnte ein Rechteck manuell in jeder beliebigen Schnittachse formatiert werden, welches dreidimensional einen Quader ergab. Jede Markierung außerhalb des Quaders wurde anschließend, aber auch für folgende Markierungen innerhalb des Projekts, verworfen. Auf diese Weise wurde zuerst die rechte, danach die linke Unterkieferhälfte, in den Bearbeitungsbereich gelegt und segmentiert.



*Abbildung 12: Beispiel eines Schweineunterkiefers in axialer Schnittebene nach Thresholding (grünes Label)*

#### 3.4.2.1.3 Nachbearbeitung

Schließlich wurde so der Hauptteil des Knochens erkannt und als grünes Label hervorgehoben. Wie jedoch in Abbildung 12 zu sehen ist, bestanden weiterhin nicht-

markierte Bereiche im Unterkiefer. Sie stellten unter anderem Teile der Spongiosa des Knochens, die Markhöhle und das Innere der Zähne (Pulpa) dar. Diese verbliebenen



Abbildung 13: Schaltfläche der Funktion "Multiple slice edit"

Löcher wurden nun durch händisches Nachbearbeiten gefüllt. Ebenso wurden Fehler des Thresholding-Prozesses korrigiert. Die Füllung der Löcher stand bei der Nachbearbeitung des Thresholding der CT-Daten im Vordergrund und soll im Folgenden beschrieben werden.

Zunächst wurde in axialer Ebene das kaudalste Schnittbild detektiert, das Löcher, beziehungsweise nicht markierte Teile des Unterkiefers, zeigte. Danach wurde unter dem Reiter „Segmentation“ die Funktion „Multiple slice edit“ aufgerufen, woraufhin sich die gleichnamige Schaltfläche öffnete (siehe Abbildung 13).

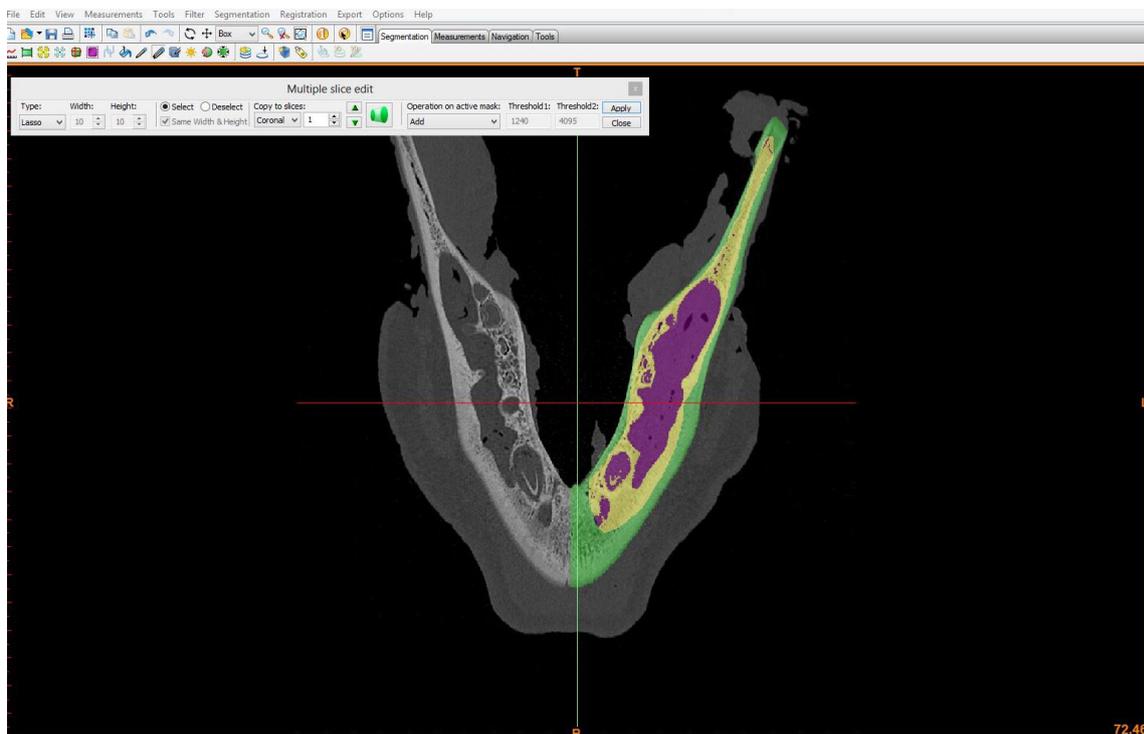


Abbildung 14: Schweineunterkiefer nach vorausgegangenem Thresholding (grüne Markierung)

Nun musste die korrekte Schnittbildebene ausgewählt werden (in diesem Fall „Axial“). Danach wurde unter „Type“ „Lasso“ ausgewählt. Dieser Editiertyp erlaubte es dem Anwender, mit der Maus einen ausgewählten Bereich zu umkreisen. Abgesehen von der Einstellung „Add“ unter „Operation on active mask“ wurden keine weiteren Änderungen mehr vorgenommen.

Wie in Abbildung 14 zu sehen, waren alle Bereiche, die bereits durch das vorherige *Thresholding* segmentiert wurden, grün (grünes Label). Die Bereiche, in denen sich die „Add“-Markierungen mit dem grünen Label überschneiden, waren gelb. Diese wurden lediglich herausgerechnet und hatten keinen Einfluss auf das bereits bestehende grüne Label. Die violette Markierung zeigte die Bereiche an, die zum grünen Label hinzugefügt wurden. Grundsätzlich wurden die Schnittbilder in axialer Bildebene von kaudal nach kranial bearbeitet.

Um zu vermeiden, jedes Schnittbild einzeln bearbeiten zu müssen, wurde die Interpolier-Funktion genutzt. Diese erlaubte es dem Anwender, wie in Abbildung 15 gezeigt, mehrere Schnittbilder zu überspringen. Dabei wurden in dieser Studie, bezogen auf die Segmentierung der CT-Daten, etwa 5 bis 10 Schnittbilder zwischenzeitlich unbearbeitet belassen und durch die Interpolier-Funktion ergänzt.

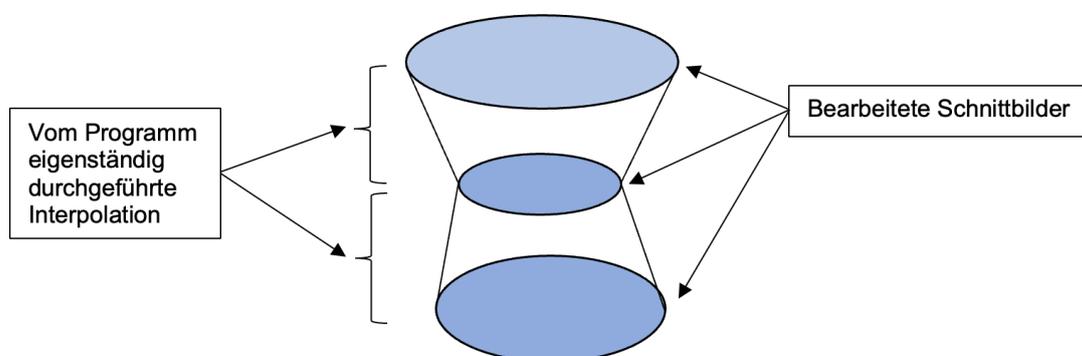
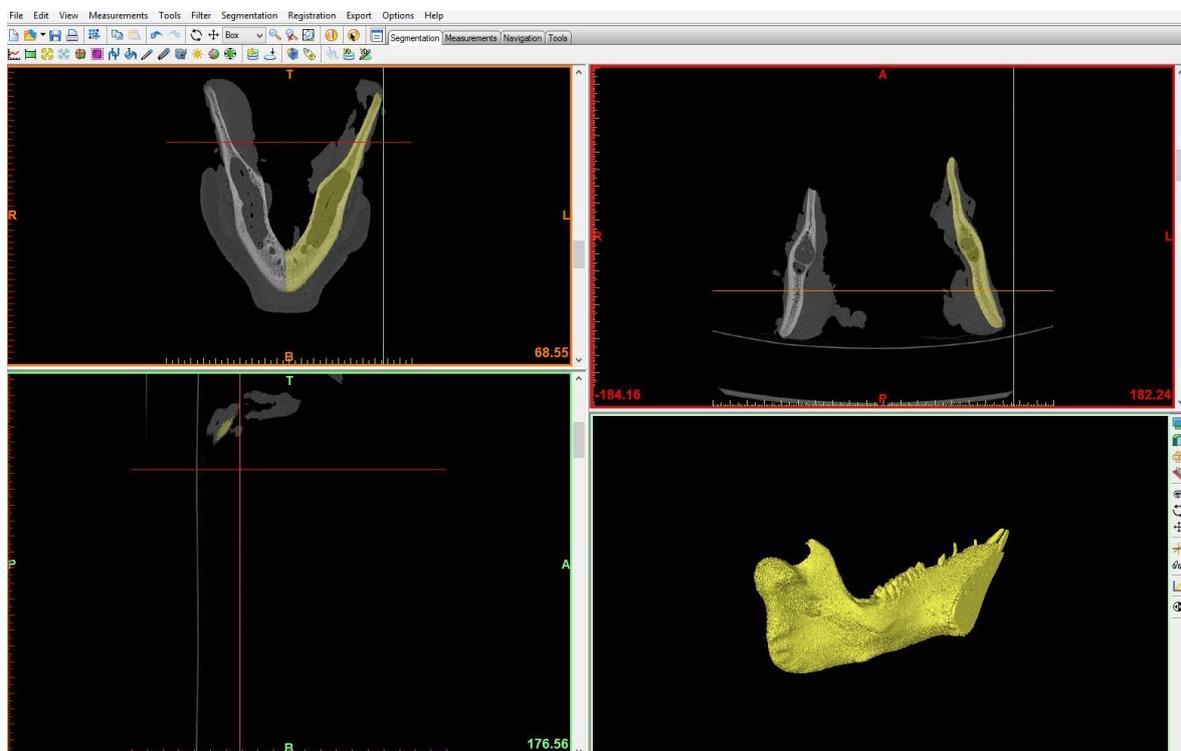


Abbildung 15: Funktionsweise der Interpolier-Funktion im Programm *Mimics Medical*

Nach anschließender Kontrolle der interpolierten Schnitte, wurde mithilfe des Befehls „Apply“ die Editierung angenommen und als fertiges Label gespeichert. Die Kontrolle der jeweiligen interpolierten Schnittbilder wurde in axialer, koronarer und sagittaler Schnittebene durchgeführt. Zum Abschluss wurde ein 3D-Objekt des gewünschten Labels durch die Funktion „Calculate 3D“ unter dem Reiter „Segmentation“, erstellt. So konnte das Ergebnis der Segmentierung in allen drei Schnittebenen und anhand des 3D-Objekts (siehe Abbildung 16) nochmals kontrolliert werden.



*Abbildung 16: Ansicht aller Schnittebenen und des 3D-Objekts nach abgeschlossener Segmentierung (Die Farbe des Labels wurde in diesem Fall von grün auf gelb geändert)*

Hierbei war es möglich und hilfreich, das generierte 3D-Objekt (in Abbildung 16 im Bildabschnitt rechts unten) zu schwenken und zu drehen, um es von allen Seiten zu inspizieren. Wenn das Ergebnis akzeptiert wurde, konnte die Segmentierung abgeschlossen werden. Hierzu wurde durch die Auswahl des gewünschten Labels, mithilfe der Funktion „STL+“, das 3D-Objekt als STL-Datei abgespeichert. Dabei wurden alle Einstellungen zur Speicherung, wie vom Programm vordefiniert, belassen.

Die Zeitmessung der Segmentierung wurde direkt nach dem Speichern, also dem Betätigen des „Save“-Buttons, angehalten und notiert.

### 3.4.2.2 Arbeitsschritte MRT

Im Folgenden soll der Ablauf der Segmentierungen der MRT-Aufnahmen mithilfe des semiautomatischen Segmentierungsalgorithmus beschrieben werden. Da die Bearbeitungsschritte im Vergleich zur Segmentierung der CT-Aufnahmen ähnlich sind, sollen hier lediglich die Unterschiede genauer dargestellt werden.

#### 3.4.2.2.1 Segmentierung vorbereiten / Datei öffnen und Schnittbild ausrichten

Die Vorbereitung der Segmentierung unterschied sich kaum von der des CT-Datensatzes. Einzig die Voreinstellung „CT compressed“ wurde nach dem Import des DICOM-Datensatzes zu „MRI compressed“ geändert, um eine adäquate Anzeige zu ermöglichen.

Nach der korrekten räumlichen Ausrichtung der Schnittebenen wurde auch hier die Zeitmessung der Segmentierung gestartet.

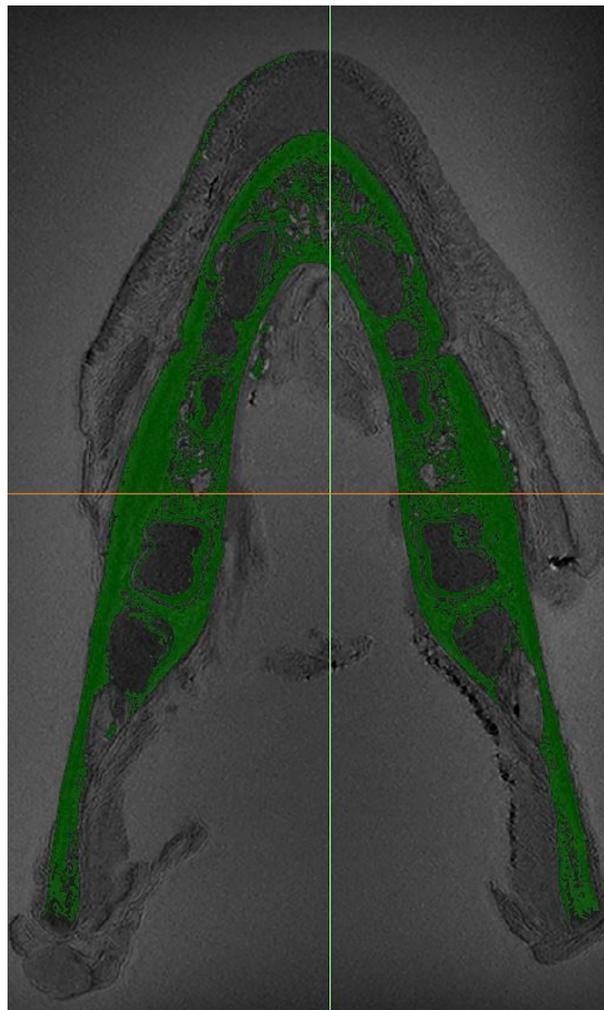
#### 3.4.2.2.2 Dynamic Region Growing und Festlegen des Zielbereichs

Für die Segmentierung der MRT-Daten wurde anstatt des *Thresholdings* auf das *Region Growing* zurückgegriffen. Hierzu wurde unter dem Reiter „Segmentation“ die Funktion „Dynamic Region Growing“ ausgewählt. Daraufhin erschien die gleichnamige



Abbildung 17: Schaltfläche der Funktion "Dynamic Region Growing" mit beispielhaften Werten

Schaltfläche, wie in Abbildung 17 zu sehen, in der einerseits ein Haken vor „Multiple Layer“ gesetzt wurde, um alle Schichtbilder der Datei zu segmentieren. Andererseits wurde „Fill Cavities“ angewählt, um, wie auch beim Thresholding der CT-Dateien, kleinere Löcher innerhalb des Knochens zu schließen. Schließlich wurde ein Seed Point festgelegt, also ein beliebiger Punkt auf dem Kiefer, der Werte zwischen 0 und 10 GV (grayscale value / Graustufenwert) angenommen hat. Ebenso wurde die Spanne des Dynamic Region Growings unter „Deviation“ bei „Min“ sowie bei „Max“ festgelegt. Es wurden jeweils Werte zwischen 40 und 50 GV ausgewählt. Der Graustufenwert sowie die „Deviation“ wurden für jeden Schweineunterkiefer innerhalb des genannten Rahmens individuell festgelegt. Das Ergebnis der „Dynamic Region



*Abbildung 18: Schweinekiefers nach vorausgegangenem Dynamic Region Growing (grünes Label)*

Growing“-Funktion ist in Abbildung 18 zu sehen. Anschließend wurde der Zielbereich, wie bei der Segmentierung der CT-Daten beschrieben, festgelegt.

#### 3.4.2.2.3 Nachbearbeitung

Wie in Abbildung 18 zu sehen, sind Bereiche erfasst worden, die nicht zum Unterkieferknochen gehören (grüne Markierungen im umgebenden Weichteilgewebe, vor allem im oberen Teil der Abbildung 18). Diese hatten in mindestens einem Schnittbild Kontakt zum gesetzten Seed Point und entsprachen den vorher eingestellten GV-Werten. Gleichermaßen kann in Abbildung 18 erkannt werden, wie Teile des Kieferknochens nicht erfasst wurden. Diese Bereiche hatten entweder keinen Kontakt zum Seed Point oder entsprachen nicht dem vordefinierten Bereich der GV-Werte.

Beide Arten von Segmentierungsmängeln wurden, analog zu der Bearbeitung der CT-Daten, durch die Funktion „Multiple slice edit“ korrigiert. Dabei wurde nach folgendem Schema vorgegangen:

Zunächst wurden die Bereiche gelöscht, die fälschlicherweise markiert wurden. Dazu wurde die Schaltfläche „Multiple slice edit“ aufgerufen (siehe Abbildung 13). Daraufhin wurde der Editiertyp unter „Type“ auf „Lasso“ gestellt. Dieser erlaubte eine genaue Einzeichnung der zu löschenden Markierungen. Ebenso musste unter „Copy to slices“ die Schnittebene angegeben werden, in der gearbeitet wurde, welche hier die axiale Ebene war. Anschließend wurde unter „Operation on active mask“ auf „Remove“ gestellt. Diese Einstellung erlaubte, alles Markierte zu entfernen. Nun wurde das kaudalste Schnittbild in axialer Ebene aufgesucht. Von hier ausgehend wurde nach kranial jedes Schnittbild korrigiert, indem händisch der Bereich gekennzeichnet wurde, der fälschlich durch das Dynamic Region Growing segmentiert wurde. Dabei wurde auf die exakte Aussparung des Kieferknochens geachtet. Zum Zwecke der

Zeitersparnis war der Gebrauch der Interpolations-Funktion auch hier von Nutzen (siehe Abbildung 15). Nachdem das kranialste Schnittbild in axialer Schnitfführung bearbeitet wurde, konnte das Ergebnis akzeptiert werden. Dies geschah, nach vorheriger visueller Kontrolle der editierten Bilder, durch Betätigung des Buttons „Apply“.

Da zu diesem Zeitpunkt alle erkennbaren falschen Markierungen entfernt werden konnten, wurden nun die residuellen Löcher des Labels aufgefüllt.

Dazu wurde im Modus „Multiple slice edit“ verblieben. Lediglich in der Einstellung unter „Operation on active mask“ wurde zu „Add“ gewechselt, um folgende Markierungen zum ausgewählten Label hinzuzufügen.

Somit wurde das kaudalste Schnittbild in axialer Schnittebene aufgesucht. Daraufhin wurden die Bereiche identifiziert, die dem Kieferknochen zuzuordnen waren, aber nicht als Label gekennzeichnet wurden. Diese wurden durch passende Markierungen mithilfe des Editiertyps „Lasso“ gekennzeichnet. Da in diesem Fall auch randbildende Teile des Kieferknochens betroffen waren, wurde zwar auch mit der Interpolier-Funktion gearbeitet, jedoch wurde die Spanne der freigelassenen zwischen den markierten Schnittbildern auf 2-5 Schnittbilder reduziert. So wurde die Chance minimiert, die Oberfläche des segmentierten 3D-Objekts zu verfälschen. Diese stellte nämlich die Grundlage des späteren Vergleichs der segmentierten Objekte dar.

Somit wurde das Label des Unterkiefers bis zum kranialsten Schnittbild korrigiert. Nach exakter Begutachtung des Ergebnisses in allen drei Schnittebenen wurde dieses mithilfe des „Apply“-Buttons akzeptiert. Zusätzlich wurde unter dem Reiter „Segmentation“ die Funktion „Calculate 3D“ genutzt. Das nun erstellte 3D-Objekt konnte von allen Seiten betrachtet werden, um sichtbare Segmentierungsfehler zu erfassen.

Folglich wurde die Segmentierung abgeschlossen, indem das gewünschte Label angewählt wurde. Die Funktion „STL+“ erlaubte es, das Ergebnis als STL-Datei zu sichern. Wie auch nach der semiautomatischen Segmentierung der CT-Daten, wurden alle vordefinierten Einstellungen belassen. Ebenfalls wurde die Zeitmessung direkt nach der Betätigung des „Save“-Buttons gestoppt und notiert.

### 3.4.3 Automatisierter Segmentierungsalgorithmus

Als Nächstes wurde die Segmentierung mithilfe des automatisierten Algorithmus der zusammenhängenden Programme *ImFusion Labels* und *ImFusion Suite* durchgeführt. Im Gegensatz zum semiautomatischen Algorithmus unterscheiden sich die Arbeitsschritte für beide Modalitäten nicht voneinander. Dementsprechend galten die folgenden Ausführungen für die Bearbeitung der CT- wie auch für die der MRT-Daten.

#### 3.4.3.1 Segmentierung vorbereiten / Datei öffnen und importieren

Nach dem Öffnen des Programms *ImFusion Labels* wurde ein neues Projekt unter „New Project“ gestartet. Es folgte die Benennung des Projekts und die Auswahl des

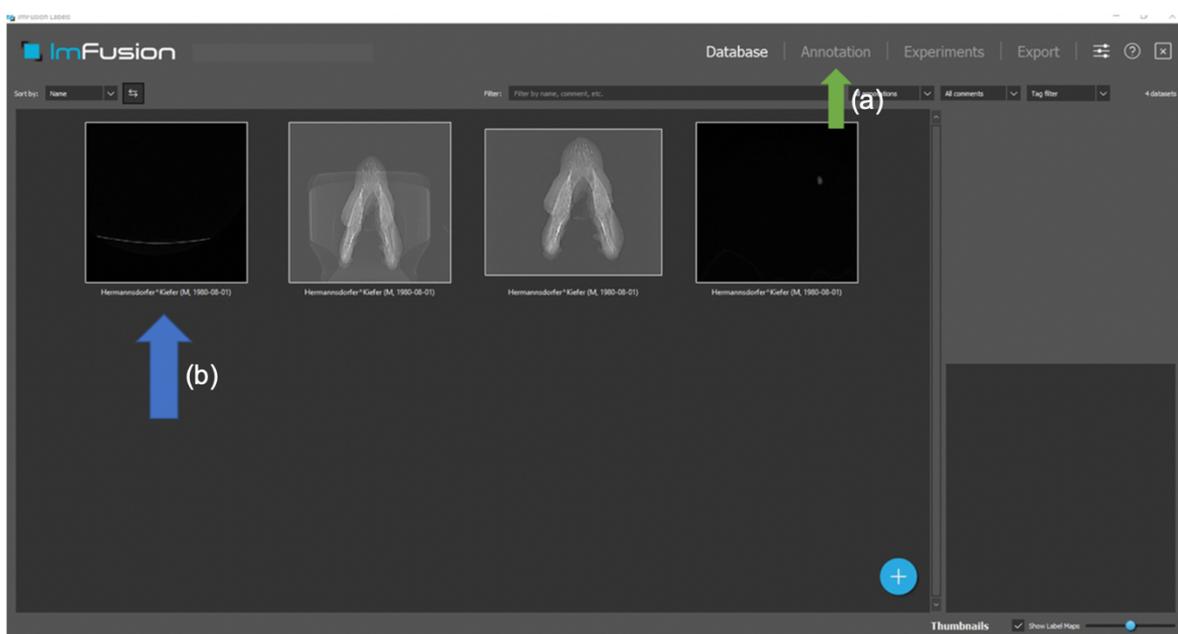


Abbildung 19: *ImFusion Labels*. Zu sehen sind die DICOM-Unterordner nach dem Import

Zielordners, woraufhin sich das Arbeitsumfeld von *ImFusion Labels* öffnete. Innerhalb der Database, dem Startpunkt des Arbeitsumfelds, wurde der Button „+“ betätigt. Dadurch wurde der Import der gewünschten DICOM-Datei initialisiert. Das „Data Import“-Fenster öffnete sich, woraufhin unter dem Reiter „DICOM“ der Ordner ausgewählt wurde, der die zu segmentierenden CT- bzw. MRT-Daten beinhaltet. Schließlich öffneten sich, nach der Betätigung des „Import“-Buttons, die Unterordner. Diese wurden als Vorschau in 1-4 Rechtecken visualisiert (Abbildung 19). Es wurde stets der erste Ordner von links ausgewählt (blauer Pfeil (b), Abbildung 19). Durch Anwählen des Ordners wechselte *ImFusion Labels* selbstständig zur Registerkarte „Annotation“ (grüner Pfeil (a), Abbildung 19). Hier begann die eigentliche Segmentierung und damit auch die Zeitmessung.

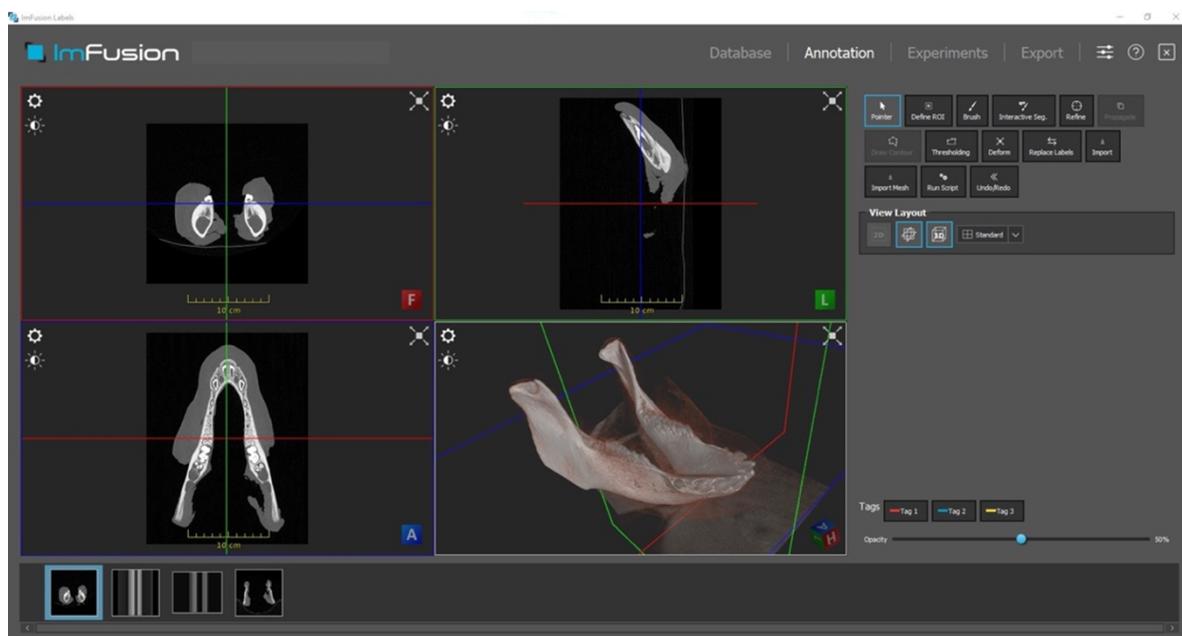


Abbildung 20: *ImFusion Labels*. Arbeitsumfeld unter "Annotation" mit allen Schnittebenen einer Schweinekiefer-CT inklusive eines vordefinierten 3D-Objekts

In der nun folgenden Arbeitsumgebung zeigten sich die CT- und MRT-Bilder im axialen, koronaren und sagittalen Schnitt (Abbildung 20). Zusätzlich erschien im rechten unteren Bereich ein vordefiniertes 3D-Objekt des Schweineunterkiefers, welches zu diesem Zeitpunkt jedoch noch nicht segmentiert war.

Zu Beginn der Segmentierung mithilfe des automatisierten Algorithmus von *ImFusion*, wurde keine Segmentierungsfunktion in Form von *Thresholding* oder *Region Growing* unternommen. Indes wurde nach Anwählen der Schaltfläche „Define ROI“ (blauer Pfeil (a), Abbildung 21) der Zielbereich festgelegt (hier bezeichnet als „Region of Interest“), indem in allen Schnittebenen ein Rechteck angepasst wurde, welches dreidimensional

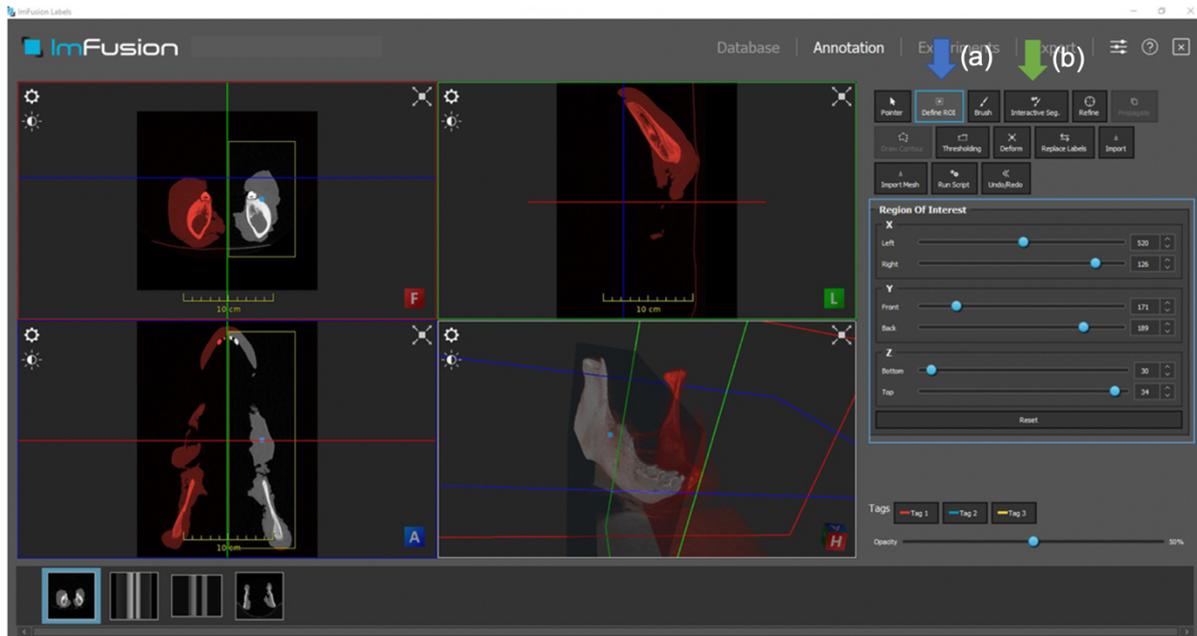


Abbildung 21: *ImFusion Labels*. Zu sehen ist das Bedienfeld zur Festlegung des Zielbereichs

einen Zielbereich in Form eines Quaders ergab. Wie in Abbildung 21 zu sehen ist, wurden alle Bereiche, die innerhalb des Zielbereichs lagen, beibehalten und weiterhin in Grautönen dargestellt. Sämtliche Regionen außerhalb des Zielbereichs wurden zwischenzeitlich rot gefärbt dargestellt. Nachdem die gewünschte Unterkieferhälfte als Zielbereich festgelegt wurde, konnte durch Betätigung der Schaltfläche „Interactive Segmentation“ fortgefahren werden (grüner Pfeil (b), Abbildung 21). Nun war lediglich der festgelegte Zielbereich in den drei Schnittebenen und dem 3D-Objekt zu sehen und damit zugänglich für die Segmentierung. Zusätzlich öffnete sich eine Schaltfläche im rechten Bildschirmabschnitt (Abbildung 22). Diese Schaltfläche wurde während des gesamten Segmentierungsprozesses genutzt, um Einstellungen des Cursors

(sogenannte „Brush Options“) vorzunehmen. Hier konnte die Größe des Cursors unter „Size“ (angegeben ist hier der Durchmesser in Millimeter) und die Anpassungsfähigkeit unter „Adaptiveness“ (angegeben als Dezimalzahl zwischen 0 und 1,0) verändert

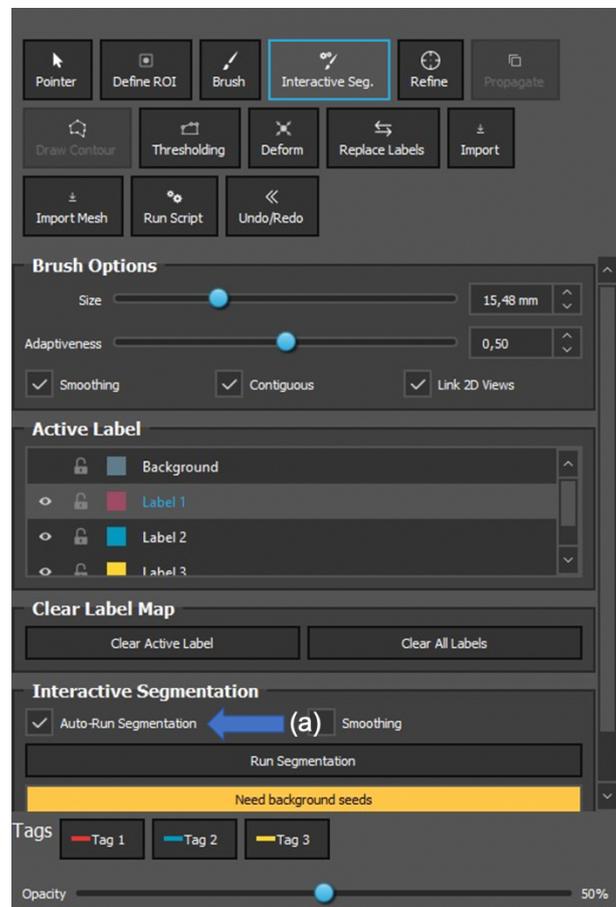


Abbildung 22: ImFusion Labels. Bildschirmausschnitt der Schaltfläche während der Segmentierung („Interactive Segmentation“)

werden. Der Faktor „Adaptiveness“ definierte, wie sehr sich der Cursor den Objekten anpasste. Je höher die Einstellung gewählt wurde, desto eher schützte es, über das Objekt hinaus zu zeichnen. Konkret bedeutete das, dass während des Hinwegfahrens mit dem Cursor über das Bild angezeigt wurde, wo das Programm den Knochen vom Weichteilgewebe beziehungsweise vom Hintergrund unterschied. Wie in Abbildung 23 schematisch gezeigt, stellt der schwarze Kreis den Cursor dar. Die weiße Fläche zeigt das Knochengewebe und die gräuliche Fläche zeigt das Weichteilgewebe. Innerhalb des Kreises ist in rot gefärbt, was das Programm für den Vordergrund

beziehungsweise den Knochen hielt. Durch Linksklick konnte die Markierung gesetzt werden, die die Knochen-Weichteil-Grenze dank der *Adaptiveness*-Einstellung respektiert und sich derer anpasst. Jedoch war zu beachten, dass bei zu hoher

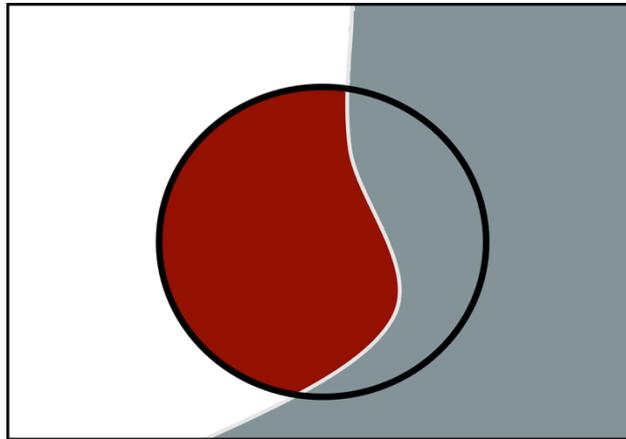


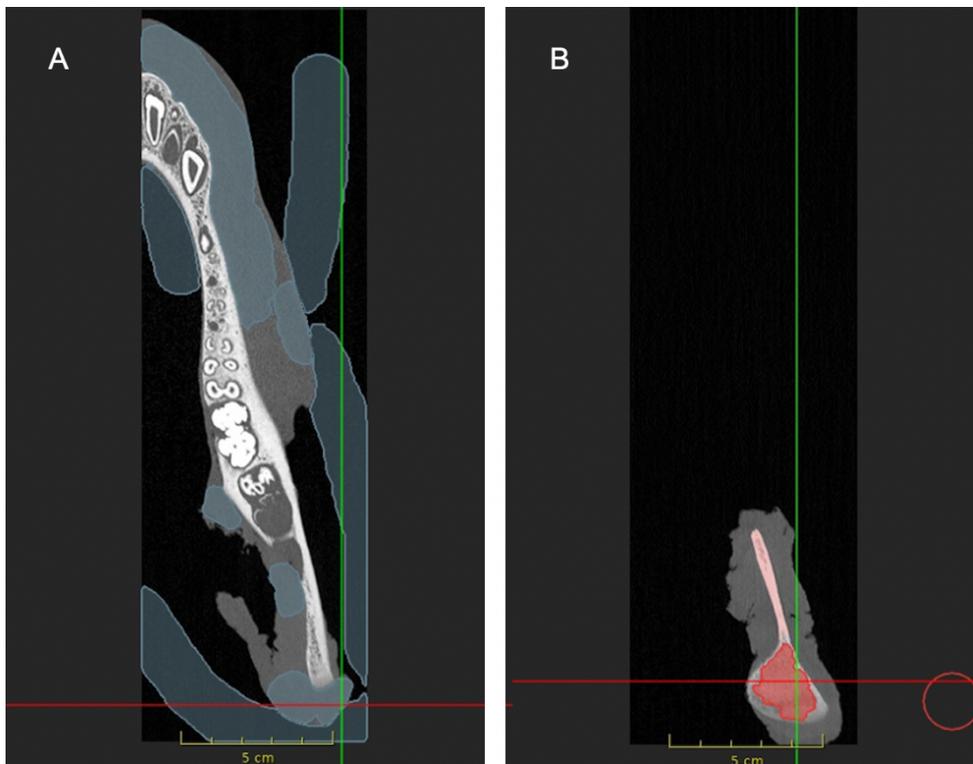
Abbildung 23: Skizze der Funktionsweise des Cursors in ImFusion Labels (Abstrakte Darstellung einer Knochen-Weichteil-Grenze)

*Adaptiveness* eine Überkorrektur stattfinden konnte. Das heißt, es wurde zu wenig markiert, weil fälschlicherweise zum Beispiel Knochen für Weichteilgewebe gehalten wurde und die Grenze des Labels deswegen nicht an der Knochengrenze gezogen wurde. Diese Überkorrektur konnte bei beiden Modalitäten mit einer *Adaptiveness* zwischen 0,3 bis 0,7 größtenteils vermieden werden. In diesem Bereich wurde die Einstellung bei Bedarf verändert, angepasst an den segmentierten Bereich des Schweineunterkiefers.

Genauer gesagt wurde bei der Segmentierung der Zähne die Größe des Cursors („Size“) eher klein, bei 6-10 mm, und die *Adaptiveness* bei 0,4-0,6 festgelegt. Beim Capitulum mandibulae (Kiefergelenksköpfchen) wurde die Größe des Cursors bei 8-12 mm und die *Adaptiveness* bei 0,5 bis 0,7 eingestellt. Der restliche Teil des Unterkiefers konnte mit einer Cursorgröße von 12-20 mm und einer *Adaptiveness* von 0,3 bis 0,5 segmentiert werden. Um den automatisierten und interaktiven Algorithmus anwenden zu können, war es essenziell, die Option „Auto-Run Segmentation“ unter

„Interactive Segmentation“ auszuwählen (blauer Pfeil, Abbildung 22). Ansonsten wurden alle anderen Voreinstellungen des Programms, beziehungsweise der Schaltfläche in Abbildung 22, belassen.

Anfangs wurde der Bildschirm für die axiale Schnittebene maximiert (Abbildung 24). Zunächst wurde das Label „Background“ unter „Active Label“ (Abbildung 22) angewählt, um den Hintergrund zu markieren. Dazu wurden, begonnen von kaudal, Background-Markierungen gesetzt.



*Abbildung 24: ImFusion Labels. Axialer Schnitt. A) Setzen der Background-Markierungen; B) Setzen der Vordergrund-Markierungen (Label 1)*

Wie in Abbildung 24 (A) zu sehen ist, wurden der schwarze Hintergrund und das den Knochen umgebende Weichteilgewebe mit den blauen Background-Markierungen versehen. Diese Markierungen wurden zunächst, nur im axialen Schnitt, in insgesamt fünf bis zehn Schnittbildern gesetzt. Als Nächstes wurde das Label 1 (Vordergrund-Label) ausgewählt. Nun wurde mit dem Cursor der Unterkieferknochen in ebenfalls

etwa fünf bis zehn Schichten markiert. In Abbildung 24 (B) ist die Markierung des Capitulum mandibulae beispielhaft dargestellt.

Während und nach dem Setzen der Label-Markierungen, berechnete die Software, auf Grundlage der gesetzten Markierungen des Vordergrund-Labels und des Background-Labels, das Vordergrund-Label über alle Schichten hinweg. Durch den automatischen Algorithmus wurde also, anhand der gesetzten Markierungen, der gesamte Unterkiefer innerhalb der „Region of Interest“ segmentiert. Ein Beispiel des vom Programm selbstständig segmentierten Teil des Kiefers wird in Abbildung 25 auszugsweise dargestellt. Im axialen Schnittbild wurde der Schnitt des Kiefers hier vollständig hellrot gefärbt angezeigt (Abbildung 25). Die Farbe zeigte an, dass es in diesem Bereich keine aktiv gesetzte Markierung durch den Anwender gab, weder Background- noch Vordergrund-Markierungen. Das heißt, dass die Segmentierung hier vollständig durch die künstliche Intelligenz des Programms durchgeführt wurde. Im Vergleich dazu ist in Abbildung 24 (B) eine aktiv gesetzte Markierung in Dunkelrot dargestellt.

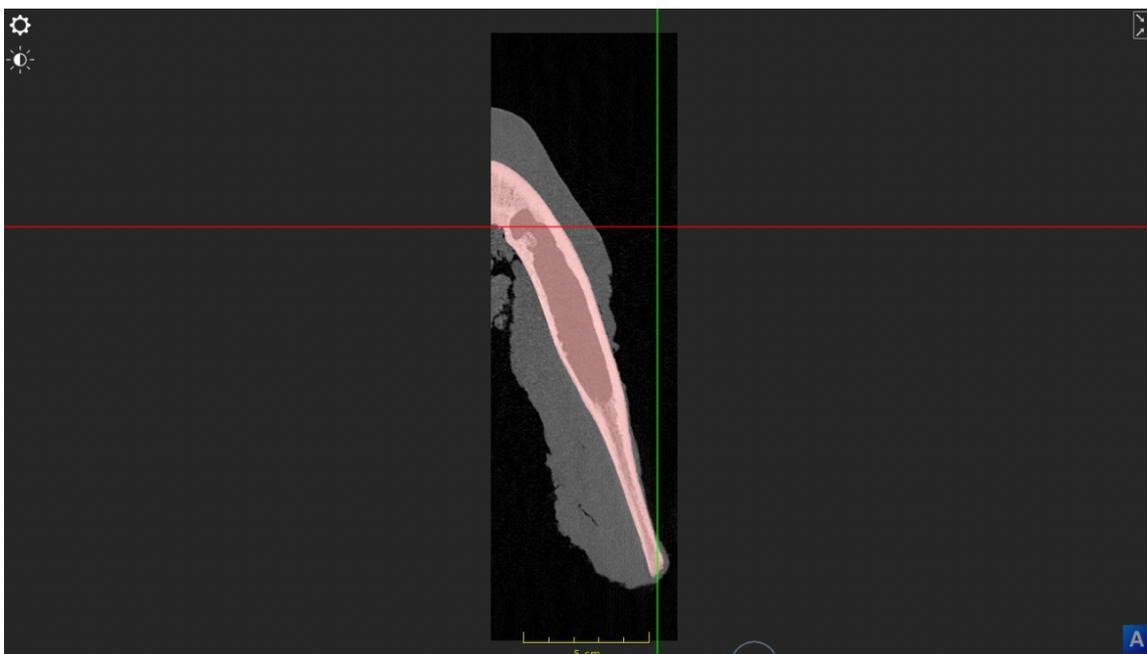


Abbildung 25: ImFusion Labels. Durch den automatisierten Algorithmus segmentierter Teil des Unterkiefers

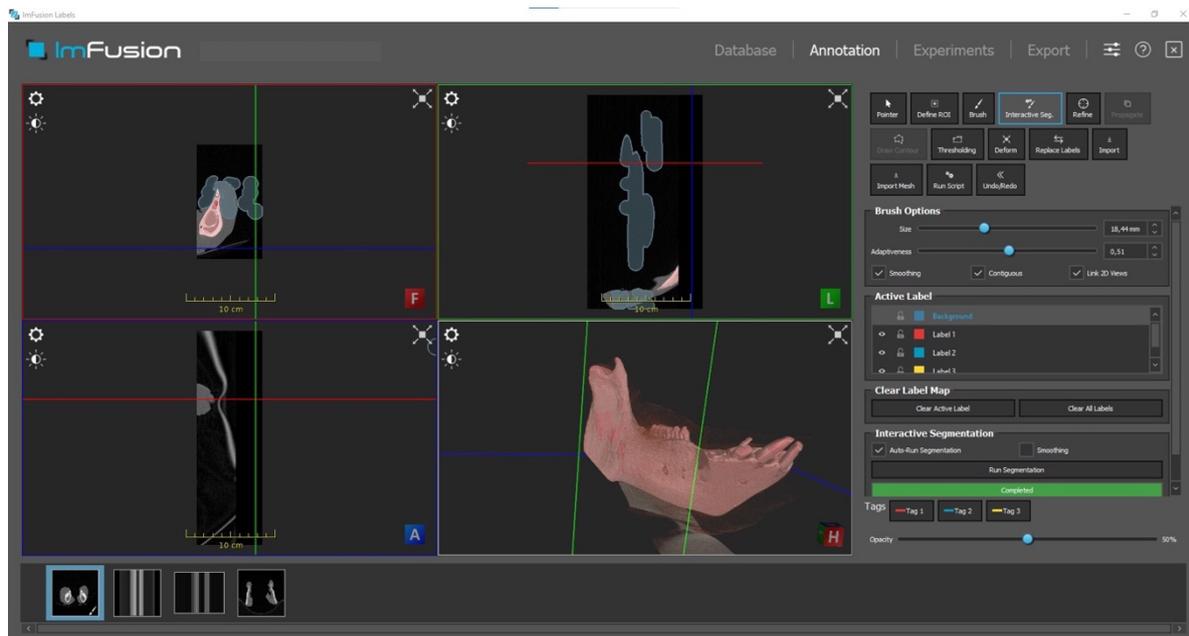


Abbildung 26: ImFusion Labels. Übersicht in Annotation nach Segmentierung

Nachdem der gesamte Kiefer auf diese Weise segmentiert werden konnte, wurde zunächst im parallel vom Programm erstellten 3D-Objekt des halben Unterkiefers kontrolliert, ob das Programm grobe Fehler gemacht hat. In diesem Fall konnten die betroffenen Bereiche gezielt in der passenden Schnittebene betrachtet und korrigiert werden (Abbildung 26). Zur Korrektur wurden fälschlicherweise als Unterkiefer markierte Bereiche mit einer Background-Markierung versehen. Teile des Schweinekiefers, welche irrtümlich nicht als dessen Bestandteil definiert wurden, konnten mit Vordergrund-Markierungen gekennzeichnet werden. Durch die zusätzlich gesetzten Markierungen an fehlerhaft segmentierten Stellen, konnte die Software weitestgehend selbstständig restliche Fehler überarbeiten.

Anschließend wurde nach erneuter Kontrolle in allen Schnittebenen das Ergebnis durch den Button „Accept Result“ im Schaltflächenbereich „Interactive Segmentation“ akzeptiert. Nach Wechseln des Arbeitsumfelds „Annotation“ zurück zu „Database“, wurde die blau hinterlegte Datei per Rechtsklick angewählt. Nach Auswahl von „Open in Suite“, öffnete sich das zugehörige Programm *ImFusion Suite* mit der bearbeiteten

Datei (Abbildung 27). Hier konnte unter Umständen erneut die passende Qualität der Segmentierung in allen Schnittebenen und im 3D-Objekt sichergestellt werden.

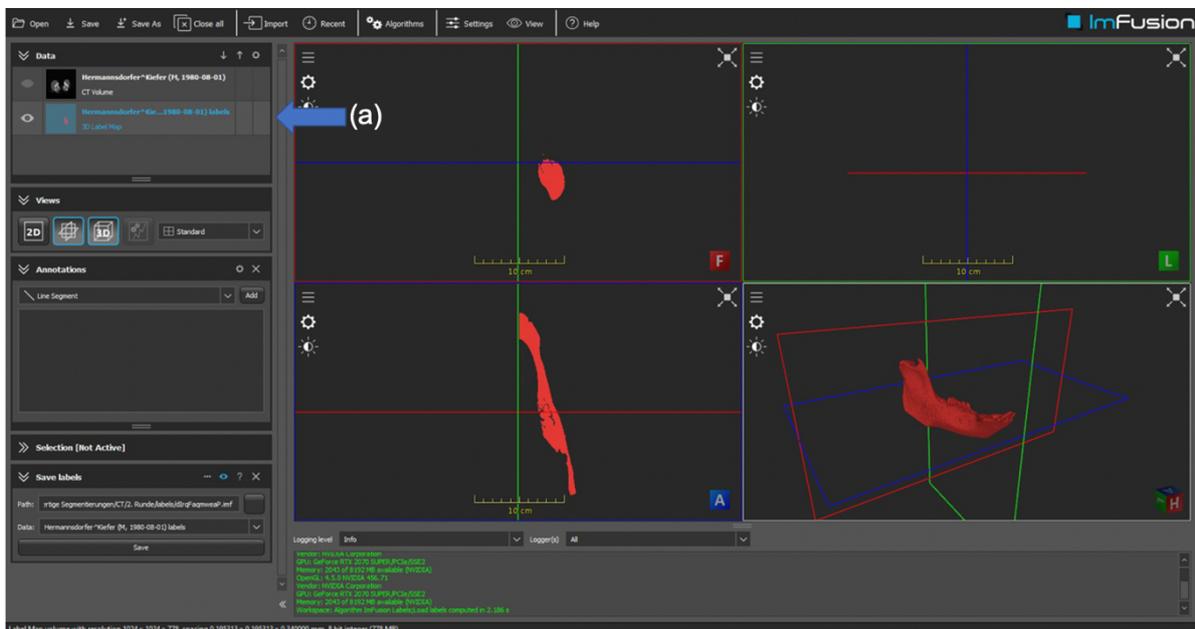


Abbildung 27: ImFusion Suite. Übersicht nach Import der bearbeiteten Datei

Durch Rechtsklick auf die im Bedienfeld „Data“ angezeigte „3D Label Map“-Datei (blauer Pfeil (a), Abbildung 27), konnte unter „Segmentation“ und weiter unter „Extract Mesh“ das 3D-Objekt extrahiert werden. Dazu öffnete sich am linken Bildschirmrand unten das Bedienfeld „Extract Mesh“ (Abbildung 28(A)). Hier wurde „Smoothing“ auf 1 gestellt. Ansonsten wurden alle Voreinstellungen belassen. Nach der Bestätigung des

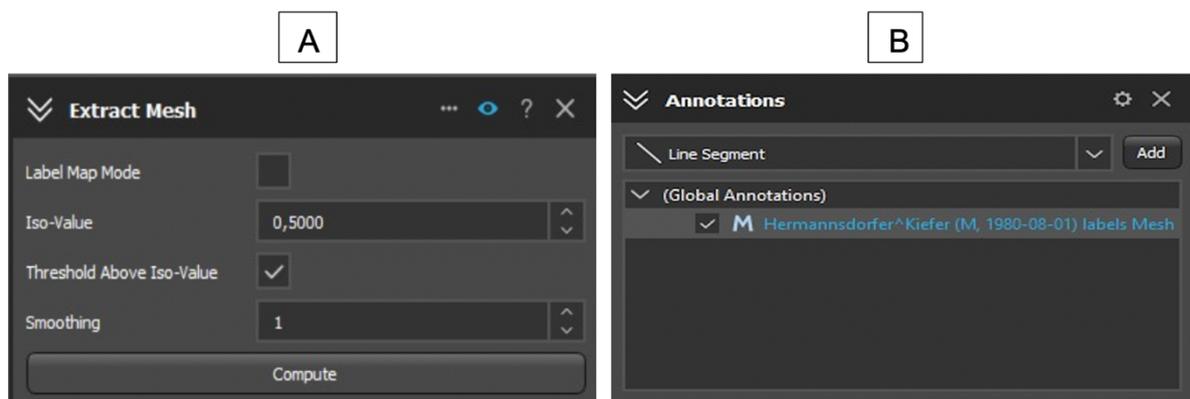


Abbildung 28: ImFusion Suite. A) Bildausschnitt der Schaltfläche "Extract Mesh"; B) Bildausschnitt der Schaltfläche "Annotations"

Buttons „Compute“, wurde nach kurzer Wartezeit das extrahierte 3D-Objekt in der Schaltfläche „Annotations“ zur Verfügung gestellt (Abbildung 28 (B)). Daraufhin wurde nach dem Rechtsklick auf die extrahierte Datei die Funktion „Export“ sowie danach „Mesh File“ ausgewählt. Nach Bestimmung des Zielordners wurde die Datei mit dem Button „Save“ als STL-Datei abgespeichert. Hier wurde die Zeitmessung der Segmentierung angehalten und notiert.

### 3.4.4 Nachbearbeitung

#### 3.4.4.1 Alignment mit 3D-Scans in Artec

Nachdem alle Segmentierungen durchgeführt wurden, standen die Unterkieferhälften als STL-Dateien zur Verfügung. Um diese nun mit den bereitgestellten optischen 3D-Scans der Schweinekiefer, die als Referenz (=Ground Truth) galten, vergleichen zu können, wurden sie mithilfe des Programms *Artec Studio Professional 12* (Artec 3D; Luxemburg) übereinandergelegt. Dazu wurden zuerst die Schweineunterkieferhälfte und der korrespondierende optische Oberflächenscan als STL-Datei importiert. Dann wurden die beiden 3D-Objekte mithilfe der Funktion „Align“ übereinandergelegt. Dazu

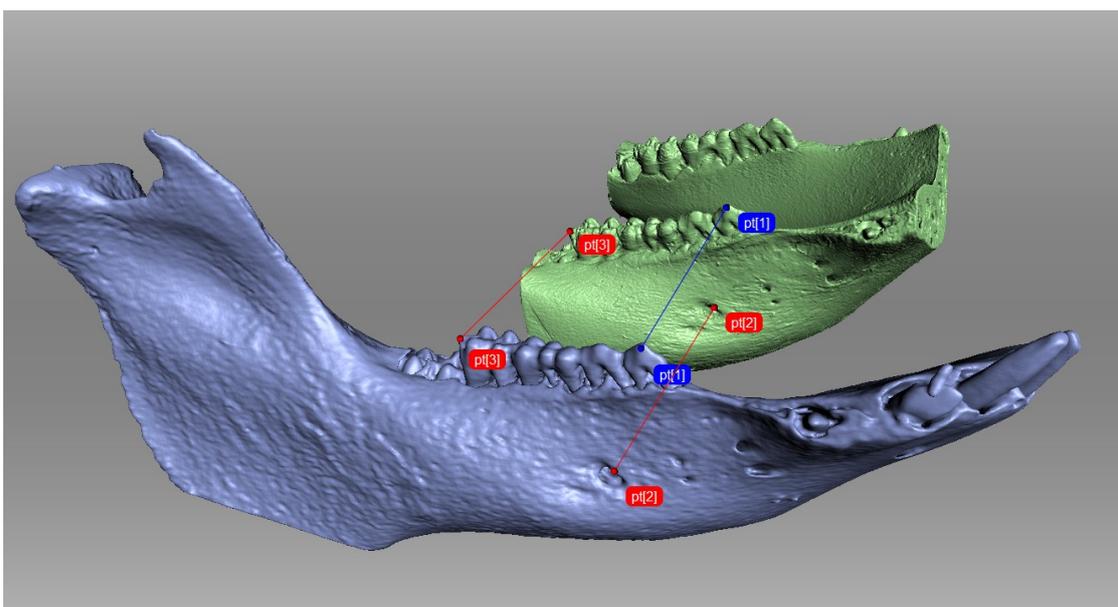


Abbildung 29: Artec Studio 12. 3-Punkt-Alignment Verfahrens nach dem Setzen der Punkte

wurde das händische „Rigid-Alignment“-Verfahren angewandt, welches nur starre, lineare Bewegungen und Rotationen bei dem Übereinanderlegen der Objekte ermöglicht, jedoch keine Änderung des Maßstabs oder ähnliche Einstellungen (Robinson et al., 2019). Dieses Verfahren erlaubte ein „3-Punkt-Alignment“. Dazu wurden drei sich entsprechende Punkte ausgewählt, die bei der Unterkieferhälfte und dem optischen Scan gut erkennbar waren. Es wurden die oberste (okklusale) Spitze des zweiten Prämolars, die distale Spitze des zweiten Molars und das Foramen mentale, wie in Abbildung 29 zu sehen, ausgewählt und an beiden korrespondierenden 3D-Objekten markiert. Anhand dieses manuellen Alignments wurde ein weiteres automatisches Alignment von dem benutzten Programm angeschlossen. Das Ergebnis des Alignments ist beispielhaft in Abbildung 30 zu sehen.

#### 3.4.4.2 Zurechtschneiden in Blender

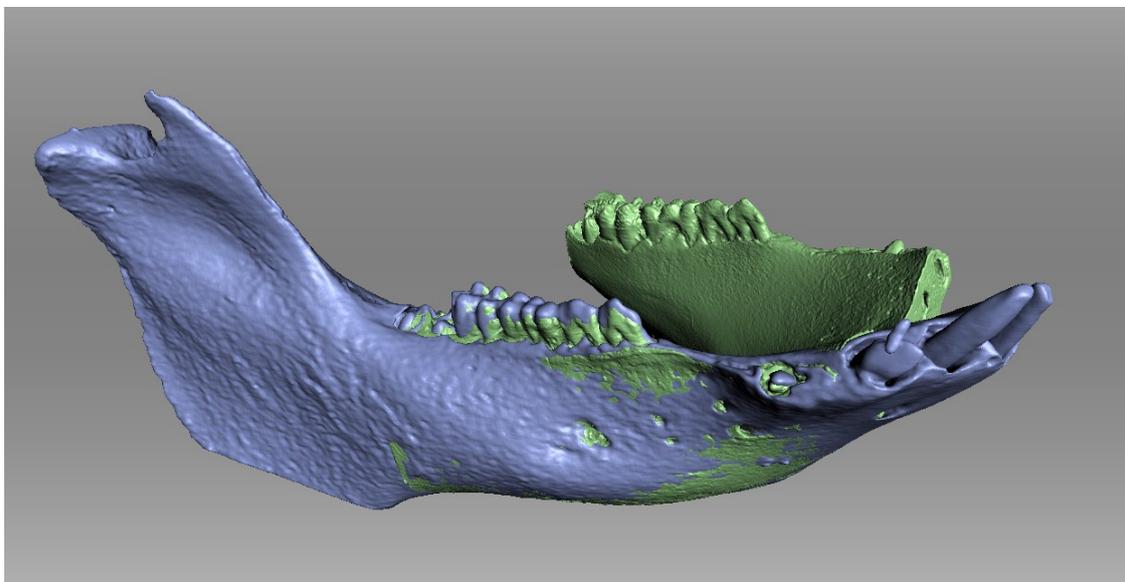


Abbildung 30: Artec Studio 12. Ergebnis des 3-Punkt-Alignments

Wie in Abbildung 30 zu sehen, stellt der optische Scan nur einen gewissen Teil des Unterkiefers zum Oberflächenvergleich bereit. Aus diesem Grund wurden überstehende Teile der vorher segmentierten Unterkieferhälfte sowie des optischen

Oberflächenscans virtuell abgeschnitten. So konnte sichergestellt werden, dass lediglich die Oberfläche im überlappenden Bereich der beiden 3D-Objekte verglichen wurde. Bei dem Prozess des Abschneidens wurde die Oberfläche der beiden Objekte im zu vergleichenden Areal nicht verändert.

Dafür wurden die vorher segmentierten Unterkieferhälften zusammen und bereits übereinandergelegt mit den optischen Scans in das Programm Blender importiert. Durch den Modifizier „Boolean“ konnte so nachträglich die Region of Interest (ROI) lediglich auf den Unterkieferkörper gelegt werden (Abbildung 31).

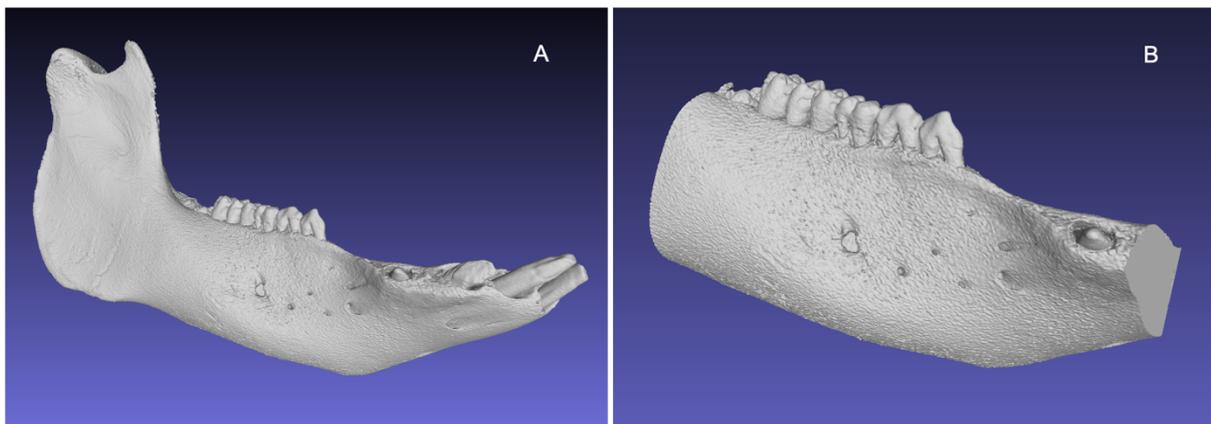


Abbildung 31: A) Unterkieferhälfte nach Segmentierung einer CT-Datei; B) An den optischen Scan angepasste Maße des Unterkiefers in (A)

#### 3.4.5 Bestimmung der Oberflächenvergleichsparameter in MeshLab

Infolgedessen standen nun alle segmentierten Unterkieferhälften und deren korrespondierende optische Scans zur Verfügung. Diese wurden nun untereinander auf geometrische Unterschiede ihrer Oberfläche untersucht. Um diese Abweichungen zu quantifizieren, wurden die in der Literatur häufig verwendeten Parameter Hausdorff-Distance (HD) (Ayyalusamy et al., 2019; Raudaschl et al., 2017; Wallner et al., 2019b), Mean Surface Distance (MSD) (Robinson et al., 2019; van Eijnatten et al., 2018) und Root Mean Square Distance (RMSD) (Gelaude et al., 2008; Ritschl et al., 2018;

Robinson et al., 2019; Smith et al., 2013) ausgewählt. Diese sollen im Folgenden kurz erklärt werden.

### **Hausdorff-Distance**

Die Hausdorff-Distance (HD) bestimmt den Grad der Nichtübereinstimmung zwischen zwei Bildsätzen basierend auf deren Umrissen. Es ist definiert als der maximale Abstand zwischen einem Punkt in einem Bildsatz A und dem nächsten Nachbarpunkt auf einem anderen Bildsatz B. Sie ist also die maximale Oberflächendistanz (Ayyalusamy et al., 2019; Huttenlocher et al., 1993; Robinson et al., 2019).

### **Mean Surface Distance**

Die Mean Surface Distance (MSD) ist der Mittelwert der Abstände zwischen jedem Oberflächenvoxel in einem Bildsatz A und dem nächsten Oberflächenvoxel in einem Bildsatz B (Robinson et al., 2019; van Eijnatten et al., 2018).

### **Root Mean Square Distance**

Die Root Mean Square Distance (RMSD) repräsentiert die Standardabweichung der Restdistanzen, welche die Abweichung von der optimalen Übereinstimmung zweier 3D-Objekte darstellen. Die RMSD wird berechnet, indem das Quadrat der Oberflächenabstände genommen, gemittelt und die Quadratwurzel gezogen wird (Robinson et al., 2019; Smith et al., 2013).

Nun wurden jeweils die segmentierten, angepassten Unterkieferhälften zusammen mit den jeweils korrespondierenden optischen 3D-Scans der Unterkiefer in das Programm *MeshLab* importiert. Ein Alignment musste an dieser Stelle nicht vorgenommen werden, da die zwei sich jeweils entsprechenden 3D-Objekte, wie vorher beschrieben, bereits im Programm *Artec Studio Professional 12* übereinandergelegt worden waren. Nach dem Import wurde unter dem Reiter „Filters“ der Unterpunkt „Sampling“ und weiter die Funktion „Hausdorff Distance“ ausgewählt. Danach öffnete sich eine gleichnamige Schaltfläche. Hier wurde als „Target Mesh“ der optische 3D-Scan eingetragen, denn er galt als Ground Truth, also als Referenz. Um die geometrische Abweichung von dem optischen Scan zu berechnen, wurde als „Sampled Mesh“ die korrespondierende, segmentierte Schweineunterkieferhälfte ausgewählt. Dann wurde die Berechnung durch den „Apply“-Button gestartet.

```
Hausdorff Distance computed
Sampled 353617 pts (rng: 0) on 1_1_Kon_a_CT_M_cutted.stl searched
closest on Kiefer 1 Scan 1_1_Kon_a_CT_M_cutted.stl
min : 0.000000 max 5.395630 mean : 0.472912 RMS : 0.640977
Values w.r.t. BBox Diag (131.201828)
min : 0.000000 max 0.041125 mean : 0.003604 RMS : 0.004885
Applied filter Hausdorff Distance in 8821 msec
```

Abbildung 32: *MeshLab*. Ausgabe der Berechnungsergebnisse

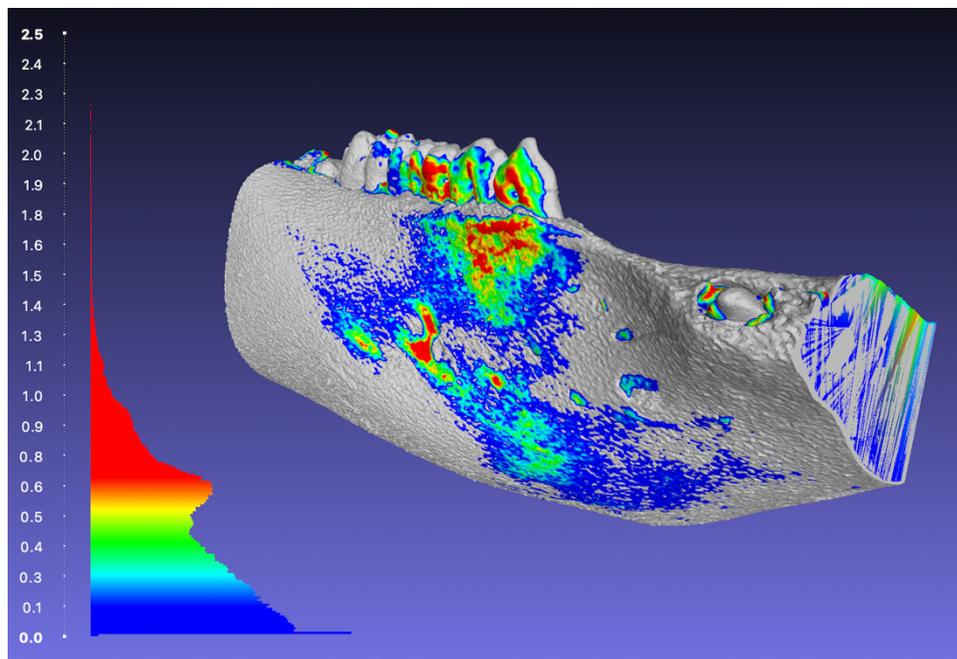
Das Ergebnis wurde im rechten unteren Bildschirmrand, wie in Abbildung 32 zu sehen, angezeigt.

Bezogen auf die Abbildung 32, hätte das Ergebnis wie folgt gelautet:

- Hausdorff Distance (der obere „max“-Wert): 5,396 mm
- Mean Surface Distance (der obere „mean“-Wert): 0,473 mm
- Root Mean Square Distance (der obere „RMS“-Wert): 0,641 mm

Die Ergebnisse wurden jeweils für jede Kieferhälfte notiert.

Um die geometrischen Abweichungen der Segmentierungsergebnisse von dem optischen 3D-Scan zu visualisieren, wurde in MeshLab ebenfalls eine Farbkarte erstellt. Diese wurde unter dem Reiter „Filters“ durch die Auswahl der Option „Color Creation and Processing“ und weiter durch die Funktion „Colorize by vertex Quality“ generiert. In der Schaltfläche „Colorize by vertex Quality“ waren die nötigen Werte bereits vordefiniert. Bei „Min“ war stets der Wert 0 angegeben und bei „Max“ der Wert, der als Hausdorff Distance zuvor berechnet wurde. Weiterhin wurden an dieser Stelle keine Einstellungen verändert.



*Abbildung 33: MeshLab. Farbkarte der Oberflächenabweichung des segmentierten Unterkiefers im Vergleich zum optischen 3D-Scan*

In Abbildung 33 ist beispielhaft eine Farbkarte des Oberflächenvergleichs gezeigt. Je röter die Stellen des Kiefers eingefärbt waren, desto größer waren die Abweichungen zur Oberfläche des optischen Scans. Bei sinkender Abweichung zeigten sich die Farben über gelblich und grünlich bis hin zu blau. Die grauen Bereiche der Abbildung zeigten die Stellen ohne nennenswerte geometrische Abweichungen zwischen dem Segmentierungsergebnis und dem optischen Scan. Auf der linken Seite der Abbildung

33 ist ein Histogramm zu sehen, welches die Verteilung der Abweichungen der jeweils entsprechenden Punkte in [mm] anzeigte.

### 3.5 Statistische Auswertung

Der Interrater- und Intrarater-Korrelationskoeffizient (ICC) wurde berechnet, um die Inter- und Intrarater-Reliabilität und -Konsistenz der Messungen zu bestimmen, die von zwei Anwendern durchgeführt wurden. Dies wurde basierend auf dem Root Mean Square Distances (RMSD) berechnet. Als primäre Zielvariable wurden dreidimensionale geometrische Abweichungen zwischen den gegebenen Segmentierungsalgorithmen, beziehungsweise den Modalitäten, und den korrespondierenden optischen 3D-Scans gesetzt. Diese Abweichungen wurden durch die HD, die MSD und die RMSD gegeben.

Als sekundäre Zielvariable wurde der Zeitaufwand für die Segmentierung einer Kieferhälfte anhand der beiden untersuchten Segmentierungsalgorithmen und -modalitäten festgelegt. Kontinuierliche Messungen werden als Median (Range) dargestellt. In nicht normalverteilten Datensätzen wurde der Wilcoxon-Rangsummentest für abhängige Stichproben verwendet. Alle statistischen Tests wurden auf einem explorativen zweiseitigen Signifikanzniveau von 5% durchgeführt. Für Mehrfachtests wurden keine Anpassungen vorgenommen.

Zur zusätzlichen Einschätzung der Übereinstimmung der Kombinationen aus den angewandten Segmentierungsalgorithmen und Modalitäten mit der gängigsten Kombination, der semiautomatischen Segmentierung von CT-Datensätzen, wurden Bland-Altman-Analysen durchgeführt. Diese zeigen deren mittlere Differenzen (MSD-Werte) und obere sowie untere *Limits of Agreement* (Mittelwert der Differenzen  $\pm 1,96$  x Standardabweichung der Differenzen). Die Analyse wurde mit der Software Excel für

Mac (Microsoft, Redmond, USA) und IBM SPSS 24 für Mac (IBM Corp, Armonk; New York, USA) durchgeführt.

## 4 Ergebnisse

### 4.1 Interrater- und Intrarater-Korrelationskoeffizient

Zwischen den Anwendern ergab sich eine Interrater-Variabilität in Form des Interrater-Korrelationskoeffizienten (ICC) von:

- CT: 0,955
- MRT: 0,915
- semiautomatischer Algorithmus: 0,933
- automatischer Algorithmus: 0,948

Für die Intrarater-Variabilität in Form des Intrarater-Korrelationskoeffizienten (ICC) ergaben sich Werte von:

- CT: 0,943/0,974
- MRT: 0,909/0,928
- semiautomatischer Algorithmus: 0,915/0,956
- automatischer Algorithmus: 0,951/0,953

### 4.2 Isolierter Vergleich der Modalitäten und Algorithmen

Im Folgenden werden die Ergebnisse des Oberflächenvergleichs zwischen den segmentierten Unterkiefen und den entsprechenden optischen 3D-Scans betrachtet. Dabei soll zum Überblick zuerst auf den Vergleich zwischen den Modalitäten (CT vs. MRT) und den Segmentierungsalgorithmen (semiautomatisch vs. automatisch) geachtet werden.

#### 4.2.1 Oberflächenvergleich

Wie der Tabelle 1 zu entnehmen, zeigten die medianen Abweichungen zwischen den Segmentierungsergebnissen der verschiedenen Modalitäten und den entsprechenden

*Tabelle 1: Gegenüberstellung der Modalitäten und Algorithmen hinsichtlich der geometrischen Abweichungen der Segmentierungsergebnisse von den optischen 3D-Scans der Schweinekiefer*

		Modalität		Algorithmus	
		CT	MRT	Semiautomatisch	Automatisch
HD (mm)	Anzahl	80	80	80	80
	Median	5,282	5,732	5,736	5,153
	Minimum	3,117	3,761	3,674	3,117
	Maximum	7,308	7,894	7,894	7,304
MSD (mm)	Anzahl	80	80	80	80
	Median	,412	,466	,502	,402
	Minimum	,308	,365	,365	,308
	Maximum	,628	,752	,752	,527
RMSD (mm)	Anzahl	80	80	80	80
	Median	,582	,679	,663	,576
	Minimum	,418	,515	,472	,418
	Maximum	,744	,851	,851	,800

optischen 3D-Scans niedrigere Werte zugunsten der CT. Dabei waren die Unterschiede zwischen CT und MRT, in Bezug auf HD, MSD und RMSD jeweils hochsignifikant ( $p < 0,001$ ).

Ebenso ist zu sehen, dass die 3D-Objekte, segmentiert mithilfe des automatischen Algorithmus, signifikant ( $p < 0,001$ ) weniger geometrische Abweichung zum optischen 3D-Scan zeigten als die Ergebnisse der semiautomatischen Segmentierung. Dies galt für alle erhobenen Oberflächenparameter.

#### 4.2.2 Segmentierungszeit

Die medianen Segmentierungszeiten der untersuchten Modalitäten waren 848 s (505–1128) für die CT-Bildgebung und 1504 s (835–2363) für die MRT-Bildgebung. Der Unterschied zwischen den Modalitäten war hochsignifikant ( $p < 0,001$ ) (Abbildung 34).

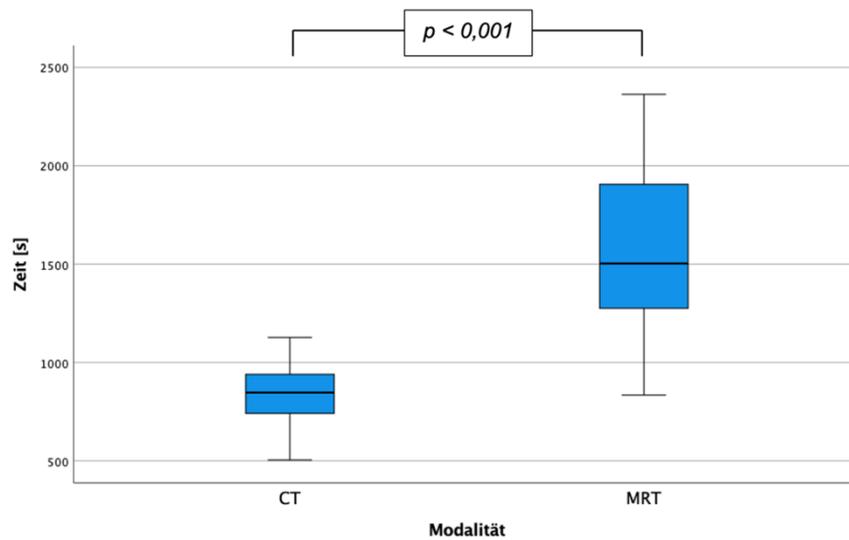


Abbildung 34: Vergleich der Segmentierungszeiten der korrespondierenden Modalitäten

Die medianen Segmentierungszeiten der angewandten Segmentierungsalgorithmen waren 1321 s (685–2363) für den semiautomatischen Algorithmus und 939 s (505–1493) für den automatischen Algorithmus. Der Unterschied zwischen den Segmentierungsalgorithmen war hochsignifikant ( $p < 0,001$ ) (Abbildung 35).

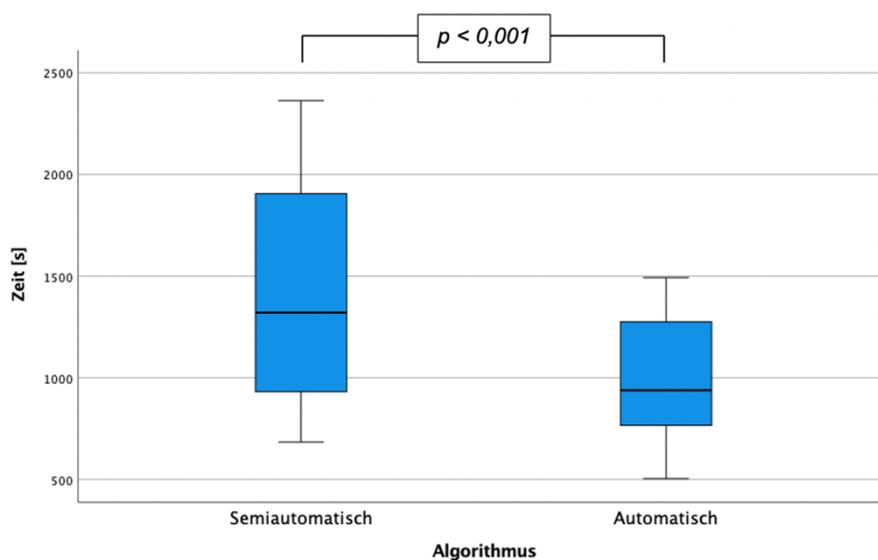


Abbildung 35: Vergleich der Segmentierungszeiten der untersuchten Segmentierungsalgorithmen

## 4.3 Kombiniertes Vergleich der Modalitäten und Algorithmen

### 4.3.1 Oberflächenvergleich

Zur genaueren Beurteilung der Daten soll nun erläutert werden, wie die heutzutage gängigste Kombination aus Algorithmus und Modalität, nämlich der semiautomatische Segmentierungsalgorithmus anhand der CT-Bildgebung, im Vergleich zu den anderen Kombinationen in dieser Studie abschnitt. Zunächst werden dazu die drei berechneten Parameter der geometrischen Abweichungen der jeweiligen segmentierten 3D-Objekte zum 3D-Scan betrachtet.

### Hausdorff-Distance

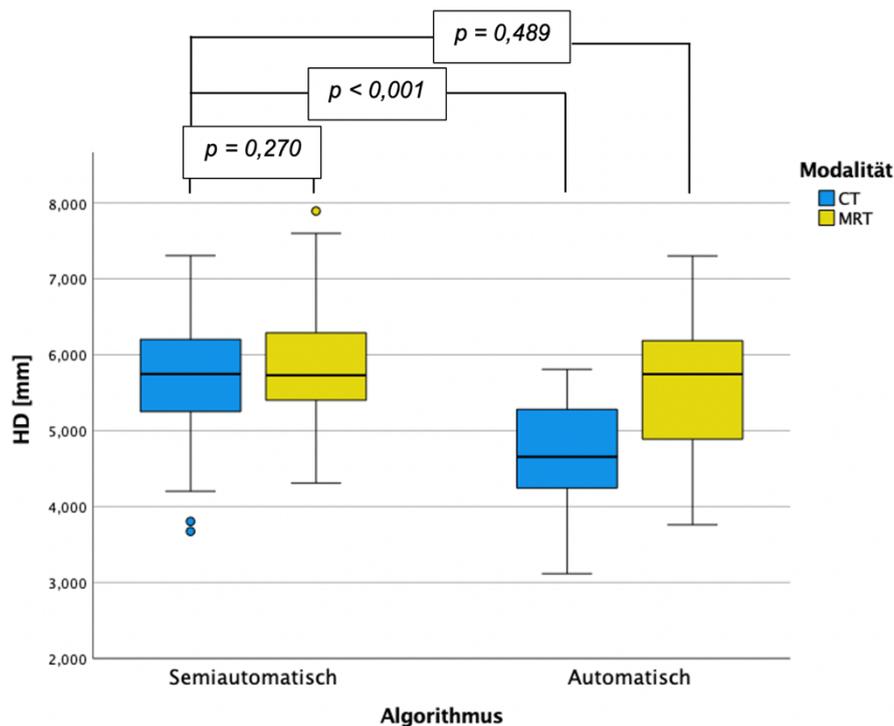


Abbildung 36: Hausdorff Distance (HD) der geometrischen Abweichung der angewandten Algorithmen und Modalitäten

Die medianen geometrischen Abweichungen in Bezug auf die HD zwischen den Segmentierungsergebnissen und den optischen Scans betragen 5,746 mm (3,674–7,308) für CT/semiautomatischen Algorithmus, 5,732 mm (4,311–7,894) für

MRT/semiautomatischen Algorithmus, 4,656 mm (3,117–5,810) für CT/automatischen Algorithmus und 5,746 mm (3,761–7,304) für MRT/automatischen Algorithmus. Nur Unterschiede zwischen CT/semiautomatischem Algorithmus und CT/automatischem Algorithmus waren statistisch signifikant ( $p < 0,001$ ) (Abbildung 36).

### Mean Surface Distance

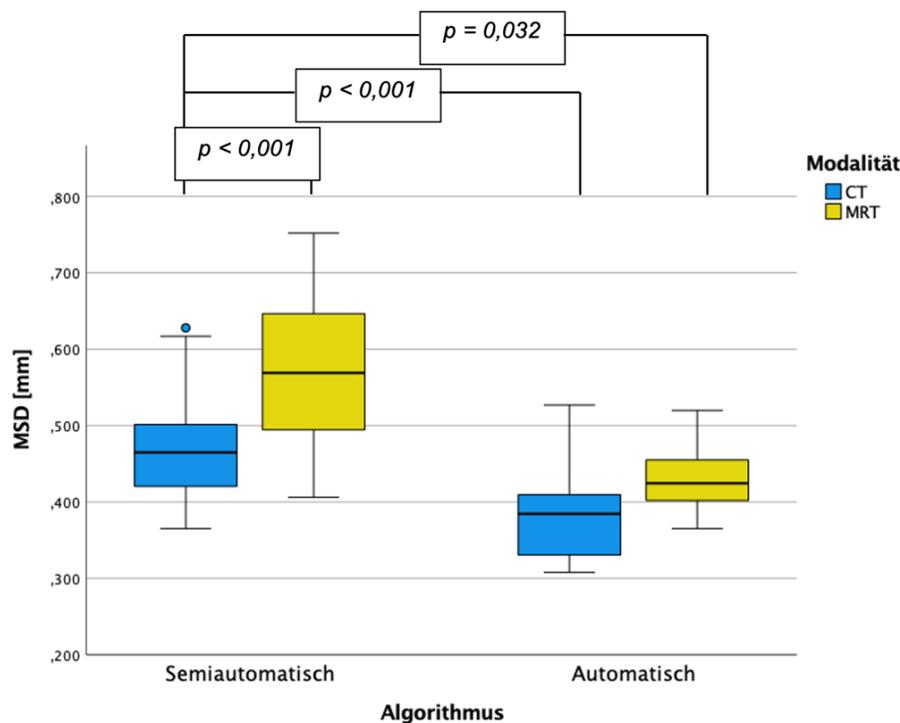


Abbildung 37: Mean Surface Distance (MSD) der geometrischen Abweichung der angewandten Algorithmen und Modalitäten

Die medianen geometrischen Abweichungen in Bezug auf die MSD zwischen den Segmentierungsergebnissen und den optischen Scans betragen 0,465 mm (0,365–0,628) für CT/semiautomatischen Algorithmus, 0,569 mm (0,406–0,752) für MRT/semiautomatischen Algorithmus, 0,385 mm (0,308–0,527) für CT/automatischen Algorithmus und 0,425 mm (0,365–0,520) für MRT/automatischen Algorithmus. Die Unterschiede zwischen CT/semiautomatischem Algorithmus, MRT/semiautomatischem Algorithmus und CT/automatischem Algorithmus waren

statistisch hoch signifikant ( $p < 0,001$ ). Die Unterschiede zwischen CT/semiautomatischem Algorithmus und MRT/automatischem Algorithmus waren ebenfalls signifikant ( $p < 0,032$ ) (Abbildung 37).

### Root Mean Square Distance

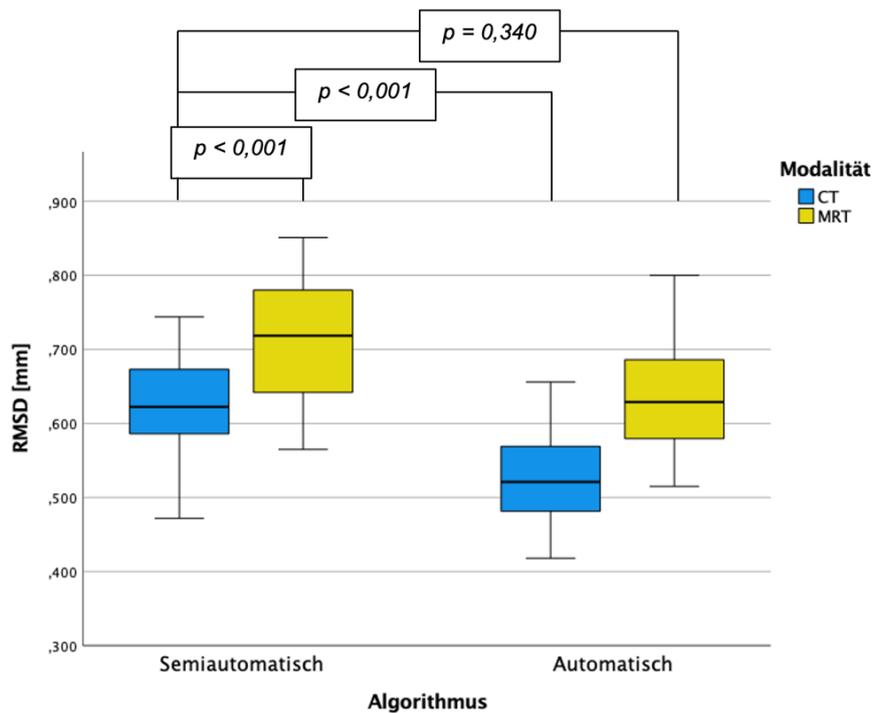


Abbildung 38: Root Mean Square Distance (RMSD) der geometrischen Abweichung der angewandten Algorithmen und Modalitäten

Die medianen geometrischen Abweichungen in Bezug auf die RMSD zwischen den Segmentierungsergebnissen und den optischen Scans betragen 0,623 mm (0,472–0,744) für CT/semiautomatischen Algorithmus, 0,718 mm (0,565–0,851) für MRT/semiautomatischen Algorithmus, 0,521 mm (0,418–0,656) für CT/automatischen Algorithmus und 0,629 mm (0,515–0,800) für MRT/automatischen Algorithmus. Die Unterschiede zwischen CT/semiautomatischem Algorithmus und MRT/semiautomatischem Algorithmus sowie CT/automatischem Algorithmus waren statistisch hoch signifikant ( $p < 0,001$ ). Unterschiede zwischen CT/semiautomatischem

Algorithmus und MRT/automatischem Algorithmus waren nicht signifikant ( $p < 0,340$ ) (Abbildung 38).

### Kombinierter Vergleich der Übereinstimmung der Modalitäten und Algorithmen

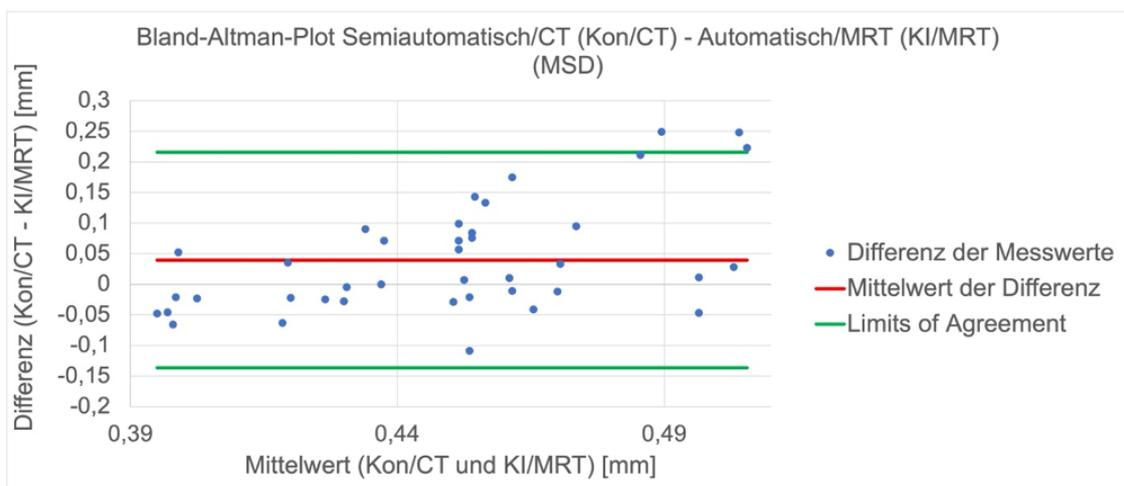
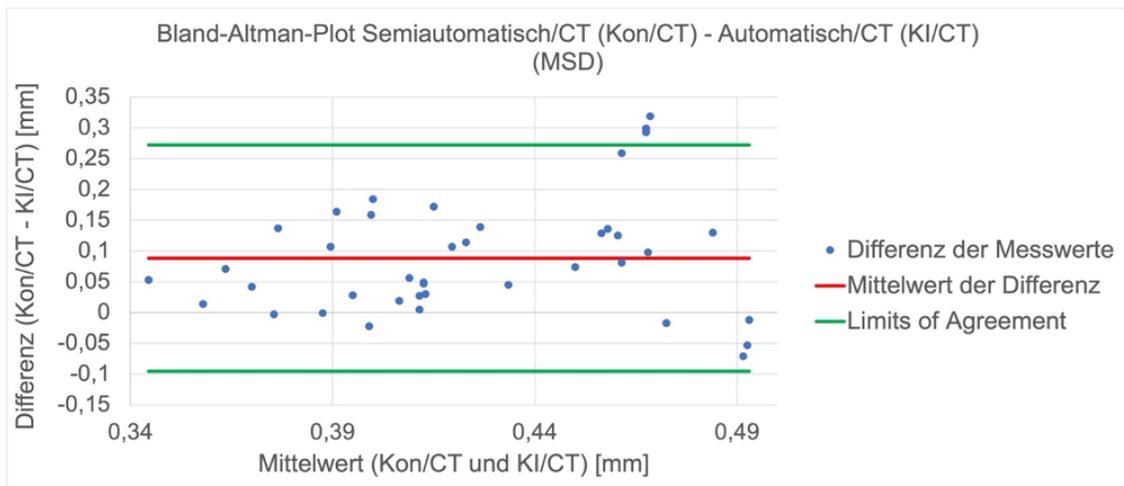
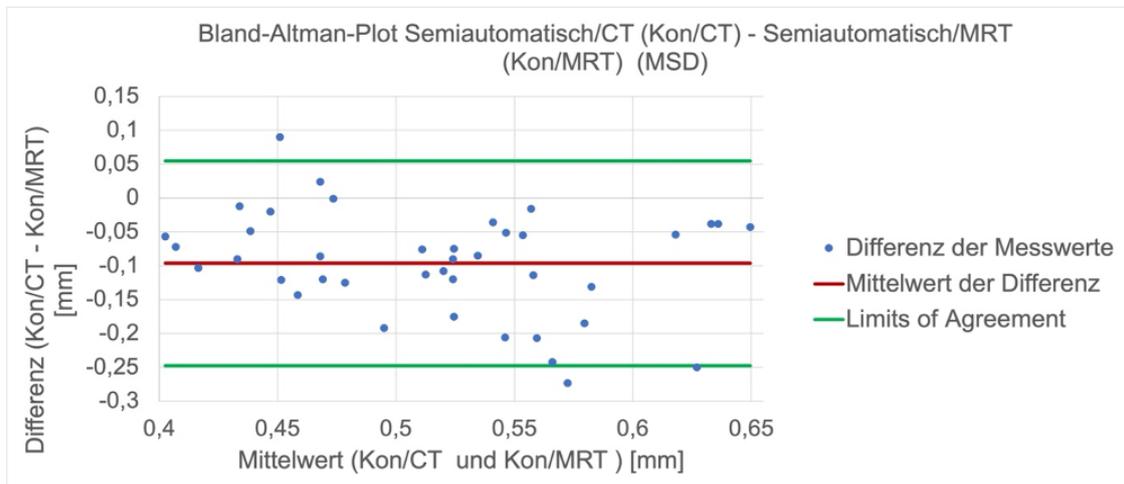


Abbildung 39: Bland-Altman-Plots zur Einschätzung der Übereinstimmung der Kombinationen aus den Segmentierungsalgorithmen und Modalitäten

Die Bland-Altman-Analysen zeigen in allen drei generierten Graphen, dass die Differenzen zwischen den Kombinationen aus den angewandten Segmentierungsalgorithmen und Modalitäten mit der gängigsten Kombination, der semiautomatischen Segmentierung von CT-Datensätzen, jeweils zu 92,5 % (37 von 40 Differenzen der verglichenen Messwerte) innerhalb der *Limits of Agreement* liegen (Abbildung 39). Dies zeigt eine hohe Übereinstimmung der verglichenen geometrischen Abweichungen anhand der MSD an.

#### 4.3.2 Segmentierungszeit

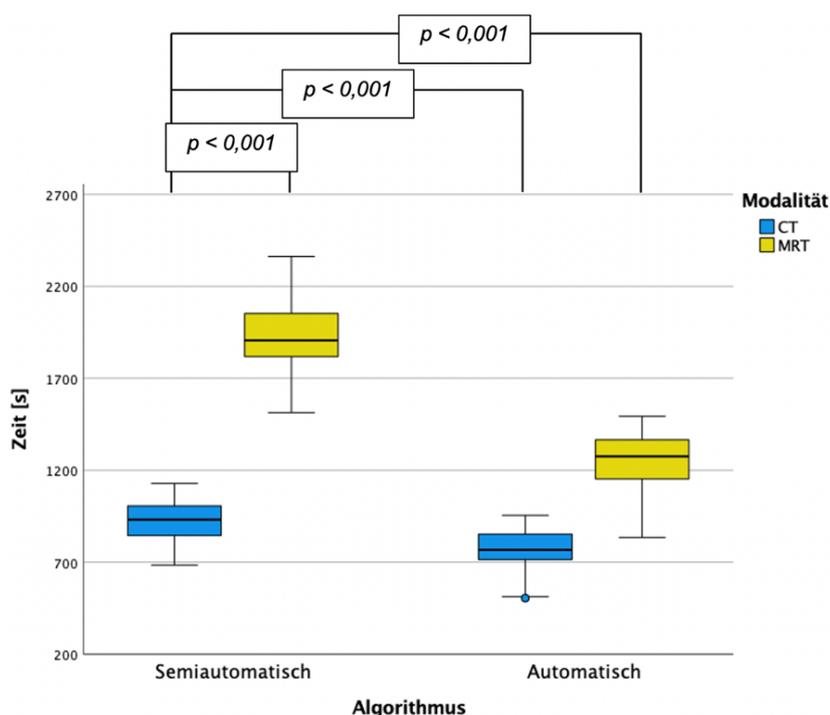


Abbildung 40: Segmentierungszeit der eingesetzten Algorithmen und Modalitäten

Die medianen Segmentierungszeiten der untersuchten Modalitäten/Algorithmen betragen 932 s (685–1128) für CT/semiautomatischen Algorithmus, 1906 s (1514–2363) für MRT/semiautomatischen Algorithmus, 767 s (505–955) für CT/automatischen Algorithmus und 1276 s (835–1493) für MRT/automatischen Algorithmus. Alle zeitlichen Unterschiede basierend auf der Kombination der

bildgebenden Modalitäten und der verwendeten Segmentierungsalgorithmen im Vergleich zu CT/semiautomatischem Algorithmus waren hochsignifikant ( $p < 0,001$ ). Somit konnte durch die Untersuchung gezeigt werden, dass die Segmentierungsdauer der CT-Daten durch den Einsatz des automatisierten Algorithmus im Median um ca. 18% verringert werden konnte. Der Einsatz der MRT-Bildgebung verlängerte die Segmentierung mithilfe des konventionellen, semiautomatischen Algorithmus um ungefähr 105%. Durch den Einsatz des automatisierten Algorithmus und der MRT-Bildgebung anstatt des semiautomatischen Algorithmus und der CT-Bildgebung zeigte sich ein zeitlicher Mehraufwand von ca. 37% (Abbildung 40).

## 5 Diskussion

### 5.1 Interrater- und Intrarater-Korrelationskoeffizient

Zunächst konnte durch die erzielten Interrater-Korrelationskoeffizienten und Intrarater-Korrelationskoeffizienten, die allesamt Werte über 0,9 annahmen, eine hohe Verlässlichkeit der Messwerte gezeigt werden. Wie in der Literatur beschrieben, weisen diese Werte auf eine sehr hohe Reliabilität der Messungen und der Methoden hin. Beispielweise sprechen Chuang et al. (2018) in ihrer Untersuchung, in der die Interrater-Variabilität zweier Anwenderinnen oder Anwender für die Unterkiefersegmentierung bei 0,73 liegt, von akzeptabler beziehungsweise guter Reliabilität der Messwerte. Grundsätzlich kann bei Werten von über 0,8 von sehr starker Übereinstimmung und damit von erheblicher Reliabilität und Objektivität gesprochen werden (Landis & Koch, 1977; Regier et al., 2013).

### 5.2 Einordnung der geometrischen Abweichungen innerhalb vergleichbarer Studien

#### **CT/semiautomatischer Algorithmus**

Wie eine Untersuchung von van Eijnatten et al. (2018) zeigte, ist das globale *Thresholding* von CT-Daten mit anschließender händischer Nachbearbeitung, also der semiautomatische Algorithmus, das gängigste Verfahren für die Segmentierung von knöchernem Gewebe. Bei Betrachtung der geometrischen Abweichungen anderer Autoren, mit Bezug auf die meistgenutzten Parameter Mean Surface Distance (MSD) und Root Mean Square Distance (RMSD), kann festgestellt werden, dass diese durchschnittlich nicht über 0,62 mm hinausgehen (Gelaide et al., 2008; van Eijnatten et al., 2018). Die meisten dieser Studien untersuchten jedoch nicht nur die anatomische Region des Unterkieferkörpers und sind damit nur eingeschränkt vergleichbar mit dieser Studie. Eine Untersuchung von van Eijnatten et al. (2016) an

menschlichen Unterkiefen mit Vergleich der Segmentierungsergebnisse mit deren entsprechenden optischen Scans zeigte für die CT-Bildgebung eine Spanne (95. Perzentil) von 0,3 bis 0,62 mm (Probst et al., 2021; van Eijnatten et al., 2016). Die zu vergleichenden medianen Abweichungen der hier durchgeführten semiautomatischen CT-basierten Segmentierungen nahmen geringere Werte an, waren aber vergleichbar niedrig. Die Unterschiede können weniger durch den Einsatz verschiedener Computertomographen und deren Einstellungen erklärt werden, welche durchaus angemessen vergleichbar waren. Wahrscheinlicher ist hier die Tatsache, dass sich die Abweichungen zwar auch ausschließlich auf den Unterkieferkörper beziehen, die Unterkiefer aber zuerst als Ganzes übereinandergelegt wurden, um dann verglichen zu werden. Auf diese Weise könnten eher Ungenauigkeiten beim Alignment-Prozess entstanden sein.

Als vergleichbarste Studie kann die Untersuchung von Probst et al. (2021) herangezogen werden, welche dieselben DICOM-Daten als Segmentierungsgrundlage nutzten. Deren erzielte geometrischen Abweichungen, anhand der CT-Bildgebung und des *Thresholdings* als angewandte Segmentierungstechnik, beliefen sich im Schnitt auf 0,225 mm (MSD) und 0,345 mm (RMSD). Die dort erfassten geometrischen Differenzen vom korrespondierenden optischen Scan lagen etwas unter den in unserer Studie erfassten Abweichungen. Diese Unterschiede können vor allem durch die eingesetzte Segmentierung oder das Alignment erklärt werden. Probst et al. (2021) legten die Schwelle des Thresholding-Verfahrens auf Werte von 600 HU und höher, nicht wie hier 226 HU und höher. Hierauf können die etwas höheren geometrischen Abweichungen in dieser Studie basieren. Ebenso ist es denkbar, dass sich die unterschiedlichen Alignment-Verfahren auf die Abweichungen der Segmentierungen zu den optischen Scans ausgewirkt haben. Durch Mai and Lee (2020) und Park et al. (2020) wurde bereits gezeigt, dass die

Genauigkeit des Oberflächenvergleichs durch die Auswahl des Alignment-Verfahrens sowie der Alignment-Software beeinflusst werden kann (Mai & Lee, 2020; Park et al., 2020). Zwar wurden in beiden Studien die Drei-Punkt-Alignment-Verfahren angewandt und mit anschließender automatischer Korrektur optimiert, jedoch kann durch die unterschiedliche Auswahl der drei korrespondierenden Punkte auf den segmentierten Unterkiefen und der optischen Scans eine geringe Abweichung der Alignments, die als Grundlage des Oberflächenvergleichs gilt, begründet sein (Mai & Lee, 2020). Wie eine Untersuchung von Flugge et al. (2017) zeigte, können die individuelle Anwendung und die vorangegangene Bearbeitung der 3D-Modelle das Alignment und damit den Vergleich der Oberflächen ebenfalls signifikant beeinflussen (Flugge et al., 2017).

### **MRT/semiautomatischer Algorithmus**

Die Untersuchung von van Eijnatten et al. (2016) zeigte für die semiautomatische Segmentierung der MRT-Bildgebung eine Spanne (95. Perzentil) von 0,86-1,30 mm für die Abweichung zu den optischen Scans. Diese liegt deutlich über unseren ermittelten geometrischen Abweichungen, was vor allem an der bereits erwähnten Tatsache liegen dürfte, dass die dort segmentierten Unterkiefer im Ganzen mit den optischen Scans übereinandergelegt wurden.

Da es derzeit wenig Daten für die semiautomatische Unterkiefersegmentierung von MRT-Daten gibt, wurde in dieser Studie, anstatt des bisher eingesetzten *Thresholdings* (Probst et al., 2021; van Eijnatten et al., 2016), das *Region Growing* zur Segmentierung ausgewählt. Es war in dieser Konstellation der Segmentierungsalgorithmus mit dem geringsten Bedarf an Nachbearbeitung. Ebendies kann der Hauptgrund sein, weshalb sich die Ergebnisse der Oberflächenvergleiche mit denen von Probst et al. (2021) etwas unterscheiden. Diese kamen durch die Segmentierung der gleichen MRT-Daten wie in unserer Studie auf geometrische Abweichungen von im Schnitt 0,280 mm (MSD)

und 0,371 mm (RMSD). Obwohl auch die von uns erzielten Abweichungen der MRT-abgeleiteten Segmentierungen vergleichbar niedrige Werte annahmen, kann dieses Ergebnis darauf hindeuten, dass das angepasste *Thresholding* der MRT-Bilder die genauere Segmentierungsmethode im Vergleich zum *Region Growing* darstellt.

### **Automatischer Algorithmus**

Bei Betrachtung des automatischen Algorithmus handelt es sich bei dem in dieser Studie untersuchten Algorithmus um einen nicht vollständig automatisch ablaufenden Prozess, wie er in anderen Studien erprobt wurde (Eley & Delso, 2020; Raudaschl et al., 2017; Tong et al., 2019; Tong et al., 2018). Der angewandte Segmentierungsalgorithmus musste nicht mit vorgehenden Daten trainiert werden und konnte somit sofort eingesetzt werden. Lediglich die bereits beschriebenen interaktiven Beiträge des Anwenders wurden benötigt, um den automatischen Anteil ablaufen zu lassen. Das hatte den zusätzlichen Vorteil, dass der Anwender selbst eine gewisse Entscheidungssicherheit hatte, die Arbeit jedoch durch den Algorithmus von *ImFusion* deutlich reduziert werden konnte. Des Weiteren zeigte sich die Anwendung des Algorithmus als äußerst schnell zu erlernen, was einen entscheidenden Faktor in der klinischen Routine darstellt. Auch wenn es kaum Untersuchungen zum Segmentierungsalgorithmus von *ImFusion* oder vergleichbaren Programmen gibt, die auf Basis der Random-Walker- und der Watershed-Segmentierung basieren, wurde dies in einer Studie von McGrath et al. (2020), jedoch bezogen auf andere anatomische Strukturen, gezeigt. Dort wurde beschrieben, dass der Algorithmus vom *ImFusion* weniger zeitlich und körperlich anstrengend in der Anwendung war, wobei die Genauigkeit zusätzlich, im Vergleich zur manuellen Segmentierung, verbessert war (McGrath et al., 2020). Beide Vorteile konnten in unserer Studie, in Hinblick auf die Unterkiefersegmentierung, bekräftigt werden.

## Einordnung der HD-Werte

Die geometrische Abweichung in Form der Hausdorff-Distance (HD) zielt nicht auf die gemittelten Differenzen der verglichenen Oberflächen ab, wie es zum Beispiel bei der MSD oder der RMSD der Fall ist, sondern auf die maximale Abweichung, die zwischen beispielsweise einem 3D-Modell eines Unterkiefers und dessen entsprechenden optischen 3D-Scans. Dieser sehr entscheidende Parameter wurde zusätzlich bestimmt, um einen Überblick über grobe Fehler und starke Ausreißer der Segmentierungen identifizieren zu können. Da selbst einzelne falsch gesetzte Pixelmarkierungen schon hohe HD-Werte zur Folge haben können, sind die in unserer Studie bestimmten Abweichungen sehr zufriedenstellend. Besonders wenn man beispielsweise die erreichten Hausdorff-Distanzen der von Raudaschl et al. (2017) beschriebenen Studie zum Vergleich betrachtet, welche verschiedene Segmentierungsalgorithmen von CT-Daten menschlicher Unterkiefer untersucht hat. Hier wurden Werte von 4,749 mm bis zu 56,128 mm beschrieben (Raudaschl et al., 2017). Im Vergleich dazu kann man in unserer Studie von geringen maximalen Abweichungen der Segmentierungsergebnisse aller untersuchten Algorithmen und Modalitäten sprechen. Besonders die automatische Segmentierung der CT-Daten erwies sich, in Bezug auf die HD-Werte, als äußerst präzise.

### 5.3 Bewertung der geometrischen Abweichungen innerhalb dieser Studie

Die Gegenüberstellung von derartig vergleichbaren Studien ist sicherlich sinnvoll, um die erzielten geometrischen Abweichungen im Kontext der virtuellen Operationsplanung einzuordnen. Dennoch sind die Resultate der verschiedenen Studien, durch Unterschiede des Studiendesigns, der Bildgebung, der untersuchten anatomischen Region oder der vielfältigen Segmentierungsalgorithmen nur bedingt hinsichtlich exakter Werte vergleichbar. Aus diesem Grund ist es vor allem wichtig,

die Distanzen der in dieser Studie angefertigten Segmentierungen zu deren korrespondierenden optischen Scans untereinander zu betrachten.

Der Vergleich mit der klinisch etablierten Kombination, also der CT-Bildgebung des Unterkiefers mit anschließender semiautomatischer Segmentierung, zeigte erstens, dass die Kombination aus MRT und semiautomatischem Algorithmus, abgesehen von der HD, stets signifikant höhere Abweichungen erzielte. Dies liegt vermeintlich nicht zuletzt daran, dass die Thresholding/Region Growing-Technik noch nicht optimal an die MRT-Daten angepasst war und es dem Anwender während der händischen Nachbearbeitung zusätzlich erschwert wurde, die Konturen mit dem menschlichen Auge zu erkennen. Die CT-Bildgebung lieferte dahingehend, trotz hinsichtlich Knochengewebe optimierter MRT-Bildgebung, immer noch die etwas besseren Kontraste und damit die genauesten Segmentierungsalgorithmen, so wie es auch die bereits erwähnten Studien zeigten.

Ebenso wurde herausgestellt, dass CT und automatischer Algorithmus, in Bezug auf alle angewandten geometrischen Vergleichsparameter, stets signifikant überlegen war. Ein Grund für die noch genaueren Ergebnisse der Segmentierungen anhand des hier angewandten automatisierten Segmentierungsalgorithmus war, dass es einerseits möglich war, die menschlichen Fehlerquellen zu minimieren. Solche Inkorrektheiten können vor allem durch die nicht exakte Festlegung des Zielbereichs der Thresholding-Funktion und der damit einhergehenden unpräzisen Definition von Knochen- und Weichteilgewebe entstehen. Weiterhin konnte die folgende händische Segmentierung, beziehungsweise die Nachbearbeitung des semiautomatischen Algorithmus, die Oberfläche des virtuellen Modells des Unterkieferknochens zusätzlich verfälschen, da die manuelle Kantenzzeichnung grundsätzlich keine exakte Abgrenzung der unterschiedlichen Gewebe versprechen kann. Andererseits konnte, durch anfängliches Setzen der Seed-Points, ein gewisser Rahmen geschaffen werden, der

dem automatischen Algorithmus vorgab, welche Gewebe voneinander segmentiert werden sollten. Dies konnte dem Anwender eine gewisse Sicherheit geben, die gewünschten Eigenschaften der Segmentierung und damit das Segmentierungsergebnis merklich zu beeinflussen.

Darüber hinaus konnte mit den Ergebnissen der Kombination aus MRT-Bildgebung mit nachfolgender automatisierter Segmentierung der Unterkiefer gezeigt werden, dass sich die Oberflächenabweichungen kaum von denen der CT-Bildgebung mit nachfolgender semiautomatischer Segmentierung unterscheiden. Somit konnte der automatisierte Algorithmus die vermeintlichen Nachteile der MRT-Knochenbildgebung auf die Segmentierungsergebnisse regelrecht abfangen. Dementsprechend ist das ein Hinweis darauf, dass sich der automatisierte Algorithmus auf Basis der Watershed- und Random-Walker-Segmentierung besser zur MRT-Knochensegmentierung eignet als der gängige semiautomatische Algorithmus. Diese Erkenntnis ist vor allem deswegen von großer Bedeutung, da diese Ergebnisse die bereits in der Literatur erzielten, mit der CT-Bildgebung vergleichbaren Resultate bestätigen. Aufgrund der Tatsache, dass die MRT den großen Vorteil der fehlenden Strahlenbelastung hat, sollte sie als potenzielle Bildgebung des Unterkiefers zur virtuellen Operationsplanung in Betracht gezogen werden. Ein weiterer Vorteil der MRT ist der ausgezeichnete Weichteilkontrast, vor allem im Vergleich zur CT. Dieser Umstand macht es möglich, trotz der umfangreichen Hardwareanforderungen und der verhältnismäßig hohen Kosten der MRT-Bildgebung (Flugge et al., 2020) sowie Kontraindikationen wie eine vorhergehende Implantation von Herzschrittmachern oder Neurostimulatoren (Probst et al., 2021), MRT-Daten für die operative Behandlungsplanung im MKG-Bereich erfolgreich nutzbar zu machen, vor allem wenn es darum geht, Weichteilgewebe in die virtuelle Operationsplanung zu integrieren. Dies konnte in mehreren Studien gezeigt werden, die insbesondere auch die geführte Zahnimplantatchirurgie (Flugge et al.,

2020; Hilgenfeld et al., 2020; Probst et al., 2020) und die Unfallchirurgie im Kiefer- und Gesichtsbereich (Burian et al., 2020b) behandelten (Probst et al., 2021). Aber auch die onkologische Resektionsplanung am Unterkiefer (Kraeima et al., 2018) und die Einbindung neurovaskulärer Strukturen mithilfe der MRT-Bildgebung (Agbaje et al., 2017; Burian et al., 2020a; Burian et al., 2020b; Probst et al., 2017) zeigten sich als sicher und akkurat. Bezogen auf die Nutzung der MRT als Grundlage der Knochensegmentierung erwies sich die „black bone“ – MRT-Sequenz als besonders genau, indem man die Darstellung der Knochen-Weichteil-Grenze durch Minimierung des Weichteilkontrasts verbessern konnte (Eley & Delso, 2020; Eley et al., 2012; Eley et al., 2017). Einerseits konnten Suchyta et al. (2018) in einer menschlichen Kadaverstudie vergleichbare Differenzen der postoperativen Abweichung zu den vorherigen Operationsplanungen am Schädeldgewölbe auf Basis der „black bone“-MRT-Sequenz und der CT-Bildgebung zeigen (Suchyta et al., 2018). Andererseits dokumentierten Suchyta et al. (2021) die Genauigkeit dieser MRT-Sequenz im Vergleich zu der CT-Bildgebung im Rahmen der CAD-/CAM-Chirurgie, beziehungsweise der Unterkieferrekonstruktion mithilfe des freien Fibulalappens (Suchyta et al., 2021). Diese Studien bestätigen, dass die Unterkiefersegmentierung anhand von MRT-Daten vergleichbar genaue Unterkiefermodelle liefern kann, wie sie anhand von CT-Daten möglich ist. Gleichwohl stellt die Unterkiefersegmentierung mithilfe des verwendeten automatischen Algorithmus eine mindestens gleichwertige Alternative zur bisher gängigen semiautomatischen Methode der Unterkiefersegmentierung dar. Dies gilt zum einen für die CT-Bildgebung, zum anderen aber auch für die MRT-Bildgebung. Hier war es durch den angewandten automatischen Algorithmus möglich, die Defizite der semiautomatischen Segmentierung der MRT-Daten auszugleichen.

Im Wesentlichen konnte auch durch die Bland-Altman-Analysen gezeigt werden, dass alle angewandten Modalitäten und Segmentierungsalgorithmen in hier kombinierter Konstellation aus klinischer Perspektive vergleichbare geometrische Abweichungen erzielen konnten, wie die CT-Bildgebung mit anschließender semiautomatischer Segmentierung. Besonders die geometrischen Abweichungen des automatisierten Algorithmus waren mindestens gleichwertig, CT-abgeleitet sogar etwas niedriger. Somit ist weder für den klinischen Gebrauch der MRT-Daten von Unterkiefern noch beim hier angewandten automatisierten Unterkiefersegmentierungsalgorithmus für die virtuelle Operationsplanung von unzureichenden Genauigkeiten der erstellten 3D-Objekte auszugehen.

#### 5.4 Zeitliche Komponente

Die zeitliche Komponente der Segmentierung spielt im klinischen Alltag eine bedeutende Rolle. Besonders die Segmentierung des Unterkiefers als Teil der operativen Behandlungsplanung kann der Anwenderin oder dem Anwender viele zeitliche Ressourcen kosten. Beispielweise beschrieben Wallner et al. (2018) Segmentierungszeiten von Unterkiefern, generiert mithilfe eines händischen Algorithmus, von 35 Minuten (2100 Sekunden) bis 46 Minuten (2760 Sekunden) (Wallner et al., 2018). Auf der anderen Seite zeigten Qiu et al. (2021) in einem Vergleich verschiedener automatischer Segmentierungsansätze Segmentierungszeiten von unter einer Sekunde bis 3-8 Stunden (Qiu et al., 2021) pro Unterkiefer. Hier unterschieden sich die verglichenen Studien jedoch sehr voneinander, besonders ist nicht klar ersichtlich, was genau mit der Bearbeitungszeit der Segmentierung gemeint ist. Da es in der Literatur also kaum vergleichbare Zeitmessungen von Unterkiefersegmentierungen gibt, ist ein direkter Vergleich mit unseren Segmentierungszeiten nicht zielführend. Das Studiendesign, die Bildgebung,

die anatomische Region und die angewandten Algorithmen unterschieden sich hier zu stark voneinander. Vielmehr macht es Sinn, analog zu den Ergebnissen der geometrischen Abweichungen, den Fokus auf den Vergleich der innerhalb dieser Studie benötigten Zeiten für die Unterkiefersegmentierungen zu legen.

Hier konnte erstens gezeigt werden, dass die CT-Bildgebung signifikant kürzere Segmentierungszeiten zur Folge hatte als die MRT-Bildgebung. Insbesondere der Unterschied innerhalb der semiautomatisch segmentierten Unterkiefer war auffällig, was vor allem durch die sehr aufwändige händische Nachbearbeitung der MRT-generierten Dateien zu erklären ist. Ebenso wurde dokumentiert, dass der automatische Algorithmus signifikant weniger Zeit beanspruchte als der semiautomatische Algorithmus. In Hinblick auf die CT-Bildgebung, zeigte sich durch die Anwendung des automatischen Algorithmus im Median eine deutlich geringere Segmentierungszeit als anhand der semiautomatischen Segmentierungen. Mithilfe des automatischen Algorithmus entfiel die manuelle Nachbearbeitung nahezu vollständig, da das Programm erstens ohnehin, nach Initialisierung des Anwenders, fast automatisch ablief und damit beinahe alle händischen Schritte des semiautomatischen Algorithmus entfielen. Zweitens, da bei fehlerhafter Segmentierung lediglich die bereits gesetzten Seed-Points mit neuen Seed-Points ergänzt wurden, bis das Ergebnis zufriedenstellend war. Dies erforderte keine händische Kantenzzeichnung der Knochen-Weichteilgrenze und sparte demnach erheblichen Zeitaufwand. So konnte das Programm von *ImFusion* durch minimalen Eintrag nicht nur die Interpolation zwischen bearbeiteten Schnittbildern übernehmen, sondern anhand weniger Markierungen ein komplettes 3D-Modell des Unterkiefers automatisch erstellen. Der Vergleich der MRT-Bildgebung gefolgt von automatischer Segmentierung mit der gängigen Kombination aus semiautomatischer Segmentierung der CT-Bilder zeigte zwar signifikant kürzere Segmentierungszeiten zugunsten der

herkömmlichen Kombination, jedoch zeigte sich der Unterschied als bedeutend geringer als der Unterschied innerhalb der semiautomatisch segmentierten Unterkiefer. Demzufolge konnte der automatische Algorithmus, wie auch bezogen auf die geometrischen Abweichungen, die vermeintlichen Nachteile der MRT-Bildgebung abmildern. Dabei konnte der zeitliche Verlust durch die Verwendung von MRT-Daten auf ein akzeptables Maß beschränkt werden.

### 5.5 Limitationen der Studie

Dennoch sind an dieser Stelle auch Einschränkungen der Studie zu nennen. Die hier verwendeten Unterkiefer von Schweinekadavern stellten, von der Bildaufnahme hin zur Segmentierung, eine gute Grundlage zur Untersuchung der bildgebenden Modalitäten und der Segmentierungsalgorithmen dar. Trotzdem konnte damit auf einzelne praktische Probleme der Unterkiefersegmentierung des Menschen nicht eingegangen werden. Erstens blieben die CT- und MRT-Aufnahmen der Schweinekiefer, wie von Probst et al. (2021) bereits beschrieben, von etwaigen Bewegungsartefakten, die durch Mobilisation der Patientinnen und Patienten während der Bildaufnahme entstehen können, verschont. Diese stellen sowohl für die CT- (Barrett & Keat, 2004) also auch für die MRT-Aufnahme (Havsteen et al., 2017) ein relevantes Problem dar, welches hier nicht berücksichtigt wurde. Zweitens waren die Schweineunterkiefer weder durch Operationen verändert noch entstanden bei der Bildakquise Artefakte durch eingebrachtes Fremdmaterial, wie Zahnfüllungen, Zahnkronen oder kieferorthopädische Vorrichtungen (Probst et al., 2021). Dieses Fremdmaterial kann auf die MRT- sowie vor allem auf die CT-Bildgebung erheblichen störenden Einfluss haben (Klinke et al., 2012). Weiterhin wurde zwar die komplette Unterkieferhälfte segmentiert, jedoch wurde hier lediglich ein Teil des Unterkieferkörpers mit dem entsprechenden optischen 3D-Scan (=Ground Truth)

verglichen. Eine größere Region of Interest, also eine größere Vergleichsoberfläche, hätte vermutlich zu stärkeren geometrischen Abweichungen geführt (Probst et al., 2021). Nicht zuletzt auch deswegen, weil die Segmentierung mehrerer zusammenhängender Strukturen schwieriger ist. Wäre das Mittelgesicht zusätzlich zum Unterkiefer in den CT- und MRT-Aufnahmen abgebildet gewesen, hätte es sich womöglich ebenfalls auf die Ergebnisse ausgewirkt.

## 6 Zusammenfassung

Ziel dieser Arbeit war es, herauszufinden, ob ein automatisierter Segmentierungsalgorithmus, im Vergleich zu der im klinischen Alltag etablierten, semiautomatischen Methode, vergleichbare Ergebnisse liefern kann. Beide Segmentierungsalgorithmen wurden jeweils auf der Basis von CT- und MRT-Daten von 10 Schweineunterkieferhälften angewandt. Die so generierten dreidimensionalen Unterkiefermodelle wurden mit korrespondierenden optischen Scans verglichen und auf geometrische Abweichungen untersucht. Die Abweichungen wurden durch die Parameter Hausdorff Distance (HD), Mean Surface Distance (MSD) und Root Mean Square Distance (RMSD) quantifiziert und durch die Untersuchung der zeitlichen Komponente der Segmentierung ergänzt. Zum einen war es durch den Gebrauch von MRT-Datensätzen möglich, präzise dreidimensionale Oberflächenmodelle der Unterkiefer von Schweinekadavern zu generieren, was insbesondere mithilfe des angewandten automatischen Segmentierungsalgorithmus realisiert werden konnte. Zum anderen ermöglichte der automatische Algorithmus von *ImFusion* eine deutliche Zeitersparnis des Segmentierungsprozesses im Vergleich zum gängigen semiautomatischen Algorithmus von *Mimics*. Dabei wurden aus klinischer Sicht allgemein akzeptable geometrischen Abweichungen erzielt, wie sie für die virtuelle Operationsplanung ausreichend sind und von gängigen Prozessen der semiautomatischen Segmentierung von CT-Daten erreicht werden.

Um nun diese Ergebnisse weiter zu stützen, sind zukünftige Untersuchungen der hier verwendeten Algorithmen, besonders auch in Verbindung mit der MRT-Bildgebung, anhand von menschlichen Unterkiefern nötig. Zusätzlich ist ein Vergleich mit weiteren Segmentierungsalgorithmen, besonders automatischer Anwendungen, sinnvoll. Als Resultat können so Schritt für Schritt die MRT-Bildgebung als Grundlage der Unterkiefersegmentierung und die automatische Segmentierung in den klinischen

Alltag integriert werden oder für unterschiedliche Fragestellungen ergänzend eingebracht werden. So kann langfristig der zeitliche und damit auch der finanzielle Aufwand minimiert werden und die Patientensicherheit sowie die Behandlungsergebnisse im operativen Feld des MKG-Bereichs können weiter optimiert werden.

## 7 Literaturverzeichnis

- Abt. für Unterricht und Medien AUM, I. f. M. L. I., Universität Bern. (2016). *RadioSurf, Prinzip der Strahlenschwächung*. Universität Bern. Retrieved 05 May 2023 from <https://radiosurf.elearning.aum.iml.unibe.ch/htmls/slide.html?radiosurf|radskullct|basics|technic|1>
- Agbaje, J. O., de Castele, E. V., Salem, A. S., Anumendem, D., Lambrichts, I., & Politis, C. (2017). Tracking of the inferior alveolar nerve: its implication in surgical planning. *Clin Oral Investig*, 21(7), 2213-2220. <https://doi.org/10.1007/s00784-016-2014-x>
- Alcântara, A. C. S., Assis, I., Prada, D., Mehle, K., Schwan, S., Costa-Paiva, L., Skaf, M. S., Wrobel, L. C., & Sollero, P. (2019). Patient-Specific Bone Multiscale Modelling, Fracture Simulation and Risk Analysis—A Survey. *Materials*, 13(1). <https://doi.org/10.3390/ma13010106>
- Antony, A. K., Chen, W. F., Kolokythas, A., Weimer, K. A., & Cohen, M. N. (2011). Use of virtual surgery and stereolithography-guided osteotomy for mandibular reconstruction with the free fibula. *Plast Reconstr Surg*, 128(5), 1080-1084. <https://doi.org/10.1097/PRS.0b013e31822b6723>
- Assaf, A. T., Zrnc, T. A., Remus, C. C., Schönfeld, M., Habermann, C. R., Riecke, B., Friedrich, R. E., Fiehler, J., Heiland, M., & Sedlacik, J. (2014). Evaluation of four different optimized magnetic-resonance-imaging sequences for visualization of dental and maxillo-mandibular structures at 3 T. *Journal of Cranio-Maxillofacial Surgery*, 42(7), 1356-1363. <https://doi.org/10.1016/j.jcms.2014.03.026>
- Avraham, T., Franco, P., Brecht, L. E., Ceradini, D. J., Saadeh, P. B., Hirsch, D. L., & Levine, J. P. (2014). Functional outcomes of virtually planned free fibula flap reconstruction of the mandible. *Plast Reconstr Surg*, 134(4), 628e-634e. <https://doi.org/10.1097/PRS.0000000000000513>
- Ayyalusamy, A., Vellaiyan, S., Subramanian, S., Ilamurugu, A., Satpathy, S., Nauman, M., Katta, G., & Madineni, A. (2019). Auto-segmentation of head and neck organs at risk in radiotherapy and its dependence on anatomic similarity. *Radiat Oncol J*, 37(2), 134-142. <https://doi.org/10.3857/roj.2019.00038>
- Badiali, G., Ferrari, V., Cutolo, F., Freschi, C., Caramella, D., Bianchi, A., & Marchetti, C. (2014). Augmented reality as an aid in maxillofacial surgery: validation of a wearable system allowing maxillary repositioning. *J Craniomaxillofac Surg*, 42(8), 1970-1976. <https://doi.org/10.1016/j.jcms.2014.09.001>
- Barrett, J., & Keat, N. (2004). Artifacts in CT: recognition and avoidance. *Radiographics*, 24(6), 1679-1691. <https://doi.org/10.1148/rg.246045065>

- Burian, E., Probst, F. A., Weidlich, D., Cornelius, C. P., Maier, L., Robl, T., Zimmer, C., Karampinos, D. C., Ritschl, L. M., & Probst, M. (2020a). MRI of the inferior alveolar nerve and lingual nerve-anatomical variation and morphometric benchmark values of nerve diameters in healthy subjects. *Clin Oral Investig*, 24(8), 2625-2634. <https://doi.org/10.1007/s00784-019-03120-7>
- Burian, E., Sollmann, N., Ritschl, L. M., Palla, B., Maier, L., Zimmer, C., Probst, F., Fichter, A., Miloro, M., & Probst, M. (2020b). High resolution MRI for quantitative assessment of inferior alveolar nerve impairment in course of mandible fractures: an imaging feasibility study. *Sci Rep*, 10(1), 11566. <https://doi.org/10.1038/s41598-020-68501-5>
- Chuang, Y. J., Doherty, B. M., Adluru, N., Chung, M. K., & Vorperian, H. K. (2018). A Novel Registration-Based Semiautomatic Mandible Segmentation Pipeline Using Computed Tomography Images to Study Mandibular Development. *J Comput Assist Tomogr*, 42(2), 306-316. <https://doi.org/10.1097/RCT.0000000000000669>
- Dell'Aversana Orabona, G., Abbate, V., Maglitto, F., Bonavolonta, P., Salzano, G., Romano, A., Reccia, A., Committeri, U., Iaconetta, G., & Califano, L. (2018). Low-cost, self-made CAD/CAM-guiding system for mandibular reconstruction. *Surg Oncol*, 27(2), 200-207. <https://doi.org/10.1016/j.suronc.2018.03.007>
- Duttenhoefer, F., Mertens, M. E., Vizkelety, J., Gremse, F., Stadelmann, V. A., & Sauerbier, S. (2015). Magnetic resonance imaging in zirconia-based dental implantology. *Clin Oral Implants Res*, 26(10), 1195-1202. <https://doi.org/10.1111/clr.12430>
- Eley, K. A., & Delso, G. (2020). Automated Segmentation of the Craniofacial Skeleton With "Black Bone" Magnetic Resonance Imaging. *J Craniofac Surg*, 31(4), 1015-1017. <https://doi.org/10.1097/SCS.00000000000006552>
- Eley, K. A., McIntyre, A. G., Watt-Smith, S. R., & Golding, S. J. (2012). "Black bone" MRI: a partial flip angle technique for radiation reduction in craniofacial imaging. *Br J Radiol*, 85(1011), 272-278. <https://doi.org/10.1259/bjr/95110289>
- Eley, K. A., Watt-Smith, S. R., & Golding, S. J. (2017). Three-Dimensional Reconstruction of the Craniofacial Skeleton With Gradient Echo Magnetic Resonance Imaging ("Black Bone"): What Is Currently Possible? *J Craniofac Surg*, 28(2), 463-467. <https://doi.org/10.1097/SCS.00000000000003219>
- Fan, Y., Beare, R., Matthews, H., Schneider, P., Kilpatrick, N., Clement, J., Claes, P., Penington, A., & Adamson, C. (2019). Marker-based watershed transform method for fully automatic mandibular segmentation from CBCT images. *Dentomaxillofac Radiol*, 48(2), 20180261. <https://doi.org/10.1259/dmfr.20180261>
- Flugge, T., Derksen, W., Te Poel, J., Hassan, B., Nelson, K., & Wismeijer, D. (2017). Registration of cone beam computed tomography data and intraoral surface

- scans - A prerequisite for guided implant surgery with CAD/CAM drilling guides. *Clin Oral Implants Res*, 28(9), 1113-1118.  
<https://doi.org/10.1111/clar.12925>
- Flugge, T., Ludwig, U., Hovener, J. B., Kohal, R., Wismeijer, D., & Nelson, K. (2020). Virtual implant planning and fully guided implant surgery using magnetic resonance imaging-Proof of principle. *Clin Oral Implants Res*, 31(6), 575-583.  
<https://doi.org/10.1111/clar.13592>
- Foley, B. D., Thayer, W. P., Honeybrook, A., McKenna, S., & Press, S. (2013). Mandibular reconstruction using computer-aided design and computer-aided manufacturing: an analysis of surgical results. *J Oral Maxillofac Surg*, 71(2), e111-119. <https://doi.org/10.1016/j.joms.2012.08.022>
- Fourie, Z., Damstra, J., Schepers, R. H., Gerrits, P. O., & Ren, Y. (2012). Segmentation process significantly influences the accuracy of 3D surface models derived from cone beam computed tomography. *Eur J Radiol*, 81(4), e524-530. <https://doi.org/10.1016/j.ejrad.2011.06.001>
- Gelaude, F., Vander Sloten, J., & Lauwers, B. (2008). Accuracy assessment of CT-based outer surface femur meshes. *Comput Aided Surg*, 13(4), 188-199.  
<https://doi.org/10.3109/10929080802195783>
- Gerber, A. J., & Peterson, B. S. (2008). What is an image? *J Am Acad Child Adolesc Psychiatry*, 47(3), 245-248. <https://doi.org/10.1097/CHI.0b013e318161e509>
- Gersing, A. S., Pfeiffer, D., Kopp, F. K., Schwaiger, B. J., Knebel, C., Haller, B., Noël, P. B., Settles, M., Rummeny, E. J., & Woertler, K. (2018). Evaluation of MR-derived CT-like images and simulated radiographs compared to conventional radiography in patients with benign and malignant bone tumors. *European Radiology*, 29(1), 13-21. <https://doi.org/10.1007/s00330-018-5450-y>
- Gonzalez, R., & Woods, R. (2017). *Digital Image Processing, EBook, Global Edition*. Pearson Education, Limited.  
<http://ebookcentral.proquest.com/lib/munchentech/detail.action?docID=5832133>
- Grady, L. (2006). Random Walks for Image Segmentation. *IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE*, 28(11), 1768-1783. <https://doi.org/10.1109/tpami.2006.233>
- Han, M. A., & Kim, J. H. (2018). Diagnostic X-Ray Exposure and Thyroid Cancer Risk: Systematic Review and Meta-Analysis. *Thyroid*, 28(2), 220-228.  
<https://doi.org/10.1089/thy.2017.0159>
- Hanken, H., Schablowsky, C., Smeets, R., Heiland, M., Sehner, S., Riecke, B., Nourwali, I., Vorwig, O., Grobe, A., & Al-Dam, A. (2015). Virtual planning of complex head and neck reconstruction results in satisfactory match between

- real outcomes and virtual models. *Clin Oral Investig*, 19(3), 647-656. <https://doi.org/10.1007/s00784-014-1291-5>
- Havsteen, I., Ohlhues, A., Madsen, K. H., Nybing, J. D., Christensen, H., & Christensen, A. (2017). Are Movement Artifacts in Magnetic Resonance Imaging a Real Problem?-A Narrative Review. *Front Neurol*, 8, 232. <https://doi.org/10.3389/fneur.2017.00232>
- Hayden, R. E., Mullin, D. P., & Patel, A. K. (2012). Reconstruction of the segmental mandibular defect: current state of the art. *Curr Opin Otolaryngol Head Neck Surg*, 20(4), 231-236. <https://doi.org/10.1097/MOO.0b013e328355d0f3>
- He, Y., Zhang, Z. Y., Zhu, H. G., Wu, Y. Q., & Fu, H. H. (2011). Double-barrel fibula vascularized free flap with dental rehabilitation for mandibular reconstruction. *J Oral Maxillofac Surg*, 69(10), 2663-2669. <https://doi.org/10.1016/j.joms.2011.02.051>
- Hidalgo, D. A. (1989). Fibula free flap: a new method of mandible reconstruction. *Plastic and Reconstructive Surgery*, 84(1), 71-79. <https://doi.org/10.1097/00006534-198907000-00014>
- Hilgenfeld, T., Juerchott, A., Jende, J. M. E., Rammelsberg, P., Heiland, S., Bendszus, M., & Schwindling, F. S. (2020). Use of dental MRI for radiation-free guided dental implant planning: a prospective, in vivo study of accuracy and reliability. *Eur Radiol*, 30(12), 6392-6401. <https://doi.org/10.1007/s00330-020-07262-1>
- Hilgenfeld, T., Prager, M., Heil, A., Schwindling, F. S., Nittka, M., Grodzki, D., Rammelsberg, P., Bendszus, M., & Heiland, S. (2017). PETRA, MSVAT-SPACE and SEMAC sequences for metal artefact reduction in dental MR imaging. *European Radiology*, 27(12), 5104-5112. <https://doi.org/10.1007/s00330-017-4901-1>
- Hirsch, D. L., Garfein, E. S., Christensen, A. M., Weimer, K. A., Saddeh, P. B., & Levine, J. P. (2009). Use of computer-aided design and computer-aided manufacturing to produce orthognathically ideal surgical outcomes: a paradigm shift in head and neck reconstruction. *J Oral Maxillofac Surg*, 67(10), 2115-2122. <https://doi.org/10.1016/j.joms.2009.02.007>
- Huff, T. J., Ludwig, P. E., & Zuniga, J. M. (2018). The potential for machine learning algorithms to improve and reduce the cost of 3-dimensional printing for surgical planning. *Expert Review of Medical Devices*, 15(5), 349-356. <https://doi.org/10.1080/17434440.2018.1473033>
- Huotilainen, E., Jaanimets, R., Valasek, J., Marcian, P., Salmi, M., Tuomi, J., Makitie, A., & Wolff, J. (2014). Inaccuracies in additive manufactured medical skull models caused by the DICOM to STL conversion process. *J Craniomaxillofac Surg*, 42(5), e259-265. <https://doi.org/10.1016/j.jcms.2013.10.001>

- Huttenlocher, D. P., Klanderman, G. A., & Rucklidge, W. J. (1993). Comparing images using the Hausdorff distance. *Transactions on Pattern Analysis and Machine Intelligence*, 15(9), 850-863. <https://doi.org/10.1109/34.232073>
- Imdad, U., Asif, M., Ahmad, M. T., Sohaib, O., Hanif, M. K., & Chaudary, M. H. (2019). Three Dimensional Point Cloud Compression and Decompression Using Polynomials of Degree One. *Symmetry*, 11(2), 209-224. <https://doi.org/10.3390/sym9030614>
- Klinke, T., Daboul, A., Maron, J., Gredes, T., Puls, R., Jaghsi, A., & Biffar, R. (2012). Artifacts in magnetic resonance imaging and computed tomography caused by dental materials. *PLoS One*, 7(2), e31766. <https://doi.org/10.1371/journal.pone.0031766>
- Kraeima, J., Dorgelo, B., Gulbitti, H. A., Steenbakkens, R., Schepman, K. P., Roodenburg, J. L. N., Spijkervet, F. K. L., Schepers, R. H., & Witjes, M. J. H. (2018). Multi-modality 3D mandibular resection planning in head and neck cancer using CT and MRI data fusion: A clinical series. *Oral Oncol*, 81, 22-28. <https://doi.org/10.1016/j.oraloncology.2018.03.013>
- Landis, J. R., & Koch, G. G. (1977). An Application of Hierarchical Kappa-type Statistics in the Assessment of Majority Agreement among Multiple Observers. *Biometrics*, 33(2), 363-374. <https://doi.org/10.2307/2529786>
- Mai, H. Y., & Lee, D. H. (2020). Impact of Matching Point Selections on Image Registration Accuracy between Optical Scan and Computed Tomography. *Biomed Res Int*, 2020, 3285431. <https://doi.org/10.1155/2020/3285431>
- Mastrogiacomo, S., Dou, W., Jansen, J. A., & Walboomers, X. F. (2019). Magnetic Resonance Imaging of Hard Tissues and Hard Tissue Engineered Bio-substitutes. *Mol Imaging Biol*, 21(6), 1003-1019. <https://doi.org/10.1007/s11307-019-01345-2>
- Mazzoni, S., Badiali, G., Lancellotti, L., Babbi, L., Bianchi, A., & Marchetti, C. (2010). Simulation-Guided Navigation. *Journal of Craniofacial Surgery*, 21(6), 1698-1705. <https://doi.org/10.1097/SCS.0b013e3181f3c6a8>
- McGrath, H., Li, P., Dorent, R., Bradford, R., Saeed, S., Bisdas, S., Ourselin, S., Shapey, J., & Vercauteren, T. (2020). Manual segmentation versus semi-automated segmentation for quantifying vestibular schwannoma volume on MRI. *Int J Comput Assist Radiol Surg*, 15(9), 1445-1455. <https://doi.org/10.1007/s11548-020-02222-y>
- Moe, J., Foss, J., Herster, R., Powell, C., Helman, J., Ward, B. B., & VanKoeveering, K. (2021). An In-House Computer-Aided Design and Computer-Aided Manufacturing Workflow for Maxillofacial Free Flap Reconstruction is Associated With a Low Cost and High Accuracy. *J Oral Maxillofac Surg*, 79(1), 227-236. <https://doi.org/10.1016/j.joms.2020.07.216>

- Moro, A., Cannas, R., Boniello, R., Gasparini, G., & Pelo, S. (2009). Techniques on modeling the vascularized free fibula flap in mandibular reconstruction. *J Craniofac Surg*, 20(5), 1571-1573.  
<https://doi.org/10.1097/SCS.0b013e3181b0db5c>
- Norouzi, A., Rahim, M. S. M., Altameem, A., Saba, T., Rad, A. E., Rehman, A., & Uddin, M. (2014). Medical Image Segmentation Methods, Algorithms, and Applications. *IETE Technical Review*, 31(3), 199-213.  
<https://doi.org/10.1080/02564602.2014.906861>
- Olabarriaga, S. D., & Smeulders, A. W. M. (2001). Interaction in the segmentation of medical images: A survey. *Medical Image Analysis*, 5(2), 127–142.  
[https://doi.org/10.1016/s1361-8415\(00\)00041-4](https://doi.org/10.1016/s1361-8415(00)00041-4)
- Orentlicher, G., Goldsmith, D., & Horowitz, A. (2010). Applications of 3-dimensional virtual computerized tomography technology in oral and maxillofacial surgery: current therapy. *J Oral Maxillofac Surg*, 68(8), 1933-1959.  
<https://doi.org/10.1016/j.joms.2010.03.013>
- Pan, Z., & Lu, J. (2007). A Bayes-Based Region-Growing Algorithm for Medical Image Segmentation. *Computing in Science & Engineering*, 9(4), 32-38.  
<https://doi.org/10.1109/mcse.2007.67>
- Park, J. H., Hwang, C. J., Choi, Y. J., Houschyar, K. S., Yu, J. H., Bae, S. Y., & Cha, J. Y. (2020). Registration of digital dental models and cone-beam computed tomography images using 3-dimensional planning software: Comparison of the accuracy according to scanning methods and software. *Am J Orthod Dentofacial Orthop*, 157(6), 843-851.  
<https://doi.org/10.1016/j.ajodo.2019.12.013>
- Pohle, R., & Toennies, K. D. (2001). Segmentation of medical images using adaptive region growing. *Medical Imaging 2001: Image Processing*, 4322.  
<https://doi.org/10.1117/12.431013>
- Prager, M., Heiland, S., Gareis, D., Hilgenfeld, T., Bendszus, M., & Gaudino, C. (2015). Dental MRI using a dedicated RF-coil at 3 Tesla. *Journal of Cranio-Maxillofacial Surgery*, 43(10), 2175-2182.  
<https://doi.org/10.1016/j.icms.2015.10.011>
- Preim, B., & Botha, C. (2013). *Visual Computing for Medicine* (2nd ed.). Elsevier.  
<https://doi.org/10.1016/b978-0-12-415873-3.00004-3>
- Probst, F. A., Burian, E., Malenova, Y., Lyutskanova, P., Stumbaum, M. J., Ritschl, L. M., Kronthaler, S., Karampinos, D., & Probst, M. (2021). Geometric accuracy of magnetic resonance imaging – derived virtual 3-dimensional bone surface models of the mandible in comparison to computed tomography and cone beam computed tomography : A porcine cadaver study. *Clinical Implant Dentistry and Related Research*, 1-10. <https://doi.org/10.1111/cid.13033>

- Probst, F. A., Schweiger, J., Stumbaum, M. J., Karampinos, D., Burian, E., & Probst, M. (2020). Magnetic resonance imaging based computer-guided dental implant surgery-A clinical pilot study. *Clin Implant Dent Relat Res*, 22(5), 612-621. <https://doi.org/10.1111/cid.12939>
- Probst, M., Richter, V., Weitz, J., Kirschke, J. S., Ganter, C., Troeltzsch, M., Nittka, M., Cornelius, C. P., Zimmer, C., & Probst, F. A. (2017). Magnetic resonance imaging of the inferior alveolar nerve with special regard to metal artifact reduction. *J Craniomaxillofac Surg*, 45(4), 558-569. <https://doi.org/10.1016/j.jcms.2017.01.009>
- Qiu, B., Guo, J., Kraeima, J., Borra, R. J. H., Witjes, M. J. H., & van Ooijen, P. M. A. (2018). 3D segmentation of mandible from multisectional CT scans by convolutional neural networks. *ArXiv*, abs/1809.06752. <https://doi.org/10.48550/ARXIV.1809.06752>
- Qiu, B., Guo, J., Kraeima, J., Glas, H. H., Borra, R. J. H., Witjes, M. J. H., & van Ooijen, P. M. A. (2019). Automatic segmentation of the mandible from computed tomography scans for 3D virtual surgical planning using the convolutional neural network. *Phys Med Biol*, 64(17), 175020. <https://doi.org/10.1088/1361-6560/ab2c95>
- Qiu, B., van der Wel, H., Kraeima, J., Glas, H. H., Guo, J., Borra, R. J. H., Witjes, M. J. H., & van Ooijen, P. M. A. (2021). Automatic Segmentation of Mandible from Conventional Methods to Deep Learning-A Review. *J Pers Med*, 11(7). <https://doi.org/10.3390/jpm11070629>
- Rajapakse, J. C., & Kruggel, F. (1998). Segmentation of MR images with intensity inhomogeneities. *Image and Vision Computing*, 16(3), 165-180. [https://doi.org/10.1016/s0262-8856\(97\)00067-x](https://doi.org/10.1016/s0262-8856(97)00067-x)
- Raudaschl, P. F., Zaffino, P., Sharp, G. C., Spadea, M. F., Chen, A., Dawant, B. M., Albrecht, T., Gass, T., Langguth, C., Luthi, M., Jung, F., Knapp, O., Wesarg, S., Mannion-Haworth, R., Bowes, M., Ashman, A., Guillard, G., Brett, A., Vincent, G., Orbes-Arteaga, M., Cardenas-Pena, D., Castellanos-Dominguez, G., Aghdasi, N., Li, Y., Berens, A., Moe, K., Hannaford, B., Schubert, R., & Fritscher, K. D. (2017). Evaluation of segmentation methods on head and neck CT: Auto-segmentation challenge 2015. *Med Phys*, 44(5), 2020-2036. <https://doi.org/10.1002/mp.12197>
- Regier, D. A., Narrow, W. E., Clarke, D. E., Kraemer, H. C., Kuramoto, S. J., Kuhl, E. A., & Kupfer, D. J. (2013). DSM-5 Field Trials in the United States and Canada, Part II: Test-Retest Reliability of Selected Categorical Diagnoses. *American Journal of Psychiatry*, 170(1), 59-70. <https://doi.org/10.1176/appi.ajp.2012.12070999>
- Rengier, F., Mehndiratta, A., von Tengg-Kobligh, H., Zechmann, C. M., Unterhinninghofen, R., Kauczor, H. U., & Giesel, F. L. (2010). 3D printing

- based on imaging data: review of medical applications. *Int J Comput Assist Radiol Surg*, 5(4), 335-341. <https://doi.org/10.1007/s11548-010-0476-x>
- Ritschl, L. M., Kilbertus, P., Grill, F. D., Schwarz, M., Weitz, J., Nieberler, M., Wolff, K. D., & Fichter, A. M. (2021a). In-House, Open-Source 3D-Software-Based, CAD/CAM-Planned Mandibular Reconstructions in 20 Consecutive Free Fibula Flap Cases: An Explorative Cross-Sectional Study With Three-Dimensional Performance Analysis. *Front Oncol*, 11, 731336. <https://doi.org/10.3389/fonc.2021.731336>
- Ritschl, L. M., Mucke, T., Fichter, A., Gull, F. D., Schmid, C., Duc, J. M. P., Kesting, M. R., Wolff, K. D., & Loeffelbein, D. J. (2017a). Functional Outcome of CAD/CAM-Assisted versus Conventional Microvascular, Fibular Free Flap Reconstruction of the Mandible: A Retrospective Study of 30 Cases. *J Reconstr Microsurg*, 33(4), 281-291. <https://doi.org/10.1055/s-0036-1597823>
- Ritschl, L. M., Mucke, T., Fichter, A. M., Roth, M., Kaltenhauser, C., Pho Duc, J. M., Kesting, M. R., Wolff, K. D., & Loeffelbein, D. J. (2017b). Axiographic results of CAD/CAM-assisted microvascular, fibular free flap reconstruction of the mandible: A prospective study of 21 consecutive cases. *J Craniomaxillofac Surg*, 45(1), 113-119. <https://doi.org/10.1016/j.jcms.2016.11.001>
- Ritschl, L. M., Mucke, T., Hart, D., Unterhuber, T., Kehl, V., Wolff, K. D., & Fichter, A. M. (2021b). Retrospective analysis of complications in 190 mandibular resections and simultaneous reconstructions with free fibula flap, iliac crest flap or reconstruction plate: a comparative single centre study. *Clin Oral Investig*, 25(5), 2905-2914. <https://doi.org/10.1007/s00784-020-03607-8>
- Ritschl, L. M., Roth, M., Fichter, A. M., Mittermeier, F., Kuschel, B., Wolff, K. D., Grill, F. D., & Loeffelbein, D. J. (2018). The possibilities of a portable low-budget three-dimensional stereophotogrammetry system in neonates: a prospective growth analysis and analysis of accuracy. *Head Face Med*, 14(1), 11. <https://doi.org/10.1186/s13005-018-0168-2>
- Robinson, R., Valindria, V. V., Bai, W., Oktay, O., Kainz, B., Suzuki, H., Sanghvi, M. M., Aung, N., Paiva, J. M., Zemrak, F., Fung, K., Lukaschuk, E., Lee, A. M., Carapella, V., Kim, Y. J., Piechnik, S. K., Neubauer, S., Petersen, S. E., Page, C., Matthews, P. M., Rueckert, D., & Glocker, B. (2019). Automated quality control in image segmentation: application to the UK Biobank cardiovascular magnetic resonance imaging study. *J Cardiovasc Magn Reson*, 21(1), 18. <https://doi.org/10.1186/s12968-019-0523-x>
- Rogowska, J. (2009). Chapter 5 - Overview and Fundamentals of Medical Image Segmentation. In I. N. Bankman (Ed.), *Handbook of Medical Image Processing and Analysis (Second Edition)* (pp. 73-90). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-012373904-9.50013-1>
- Rommel, N., Kesting, M. R., Rohleder, N. H., Bauer, F. M. J., Wolff, K. D., & Weitz, J. (2017). Mandible reconstruction with free fibula flaps: Outcome of a cost-

- effective individual planning concept compared with virtual surgical planning. *J Craniomaxillofac Surg*, 45(8), 1246-1250.  
<https://doi.org/10.1016/j.jcms.2017.04.010>
- Roser, S. M., Ramachandra, S., Blair, H., Grist, W., Carlson, G. W., Christensen, A. M., Weimer, K. A., & Steed, M. B. (2010). The accuracy of virtual surgical planning in free fibula mandibular reconstruction: comparison of planned and final results. *J Oral Maxillofac Surg*, 68(11), 2824-2832.  
<https://doi.org/10.1016/j.joms.2010.06.177>
- Sieira Gil, R., Roig, A. M., Obispo, C. A., Morla, A., Pages, C. M., & Perez, J. L. (2015). Surgical planning and microvascular reconstruction of the mandible with a fibular flap using computer-aided design, rapid prototype modelling, and precontoured titanium reconstruction plates: a prospective study. *Br J Oral Maxillofac Surg*, 53(1), 49-53. <https://doi.org/10.1016/j.bjoms.2014.09.015>
- Smith, E. J., Anstey, J. A., Venne, G., & Ellis, R. E. (2013). Using additive manufacturing in accuracy evaluation of reconstructions from computed tomography. *Proc Inst Mech Eng H*, 227(5), 551-559.  
<https://doi.org/10.1177/0954411912474612>
- Stoor, P., Suomalainen, A., Lindqvist, C., Mesimäki, K., Danielsson, D., Westermarck, A., & Kontio, R. K. (2014). Rapid prototyped patient specific implants for reconstruction of orbital wall defects. *Journal of Cranio-Maxillofacial Surgery*, 42(8), 1644-1649. <https://doi.org/10.1016/j.jcms.2014.05.006>
- Suchyta, M. A., Gibreel, W., Hunt, C. H., Gorny, K. R., Bernstein, M. A., & Mardini, S. (2018). Using Black Bone Magnetic Resonance Imaging in Craniofacial Virtual Surgical Planning: A Comparative Cadaver Study. *Plastic and Reconstructive Surgery*, 141(6), 1459-1470. <https://doi.org/10.1097/prs.0000000000004396>
- Suchyta, M. A., Gibreel, W., Sabbagh, M. D., Hunt, C. H., Gorny, K. R., Lu, A., & Mardini, S. (2021). Using Black Bone Magnetic Resonance Imaging for Fibula Free Flap Surgical Planning: A Means to Reduce Radiation Exposure with Accurate Surgical Outcomes. *Plastic and Reconstructive Surgery*, 148(1), 77e-82e. <https://doi.org/10.1097/prs.00000000000008090>
- Sugg, S. (2005). *Wasserscheiden-Ansätze zur Bildsegmentierung I*.  
[https://www.mathematik.uni-ulm.de/stochastik/lehre/ws05\\_06/seminar/sugg.pdf](https://www.mathematik.uni-ulm.de/stochastik/lehre/ws05_06/seminar/sugg.pdf)
- Tarsitano, A., Ciocca, L., Scotti, R., & Marchetti, C. (2016). Morphological results of customized microvascular mandibular reconstruction: A comparative study. *J Craniomaxillofac Surg*, 44(6), 697-702.  
<https://doi.org/10.1016/j.jcms.2016.03.007>
- Tong, N., Gou, S., Yang, S., Cao, M., & Sheng, K. (2019). Shape constrained fully convolutional DenseNet with adversarial training for multiorgan segmentation

- on head and neck CT and low-field MR images. *Med Phys*, 46(6), 2669-2682. <https://doi.org/10.1002/mp.13553>
- Tong, N., Gou, S., Yang, S., Ruan, D., & Sheng, K. (2018). Fully automatic multi-organ segmentation for head and neck cancer radiotherapy using shape representation model constrained fully convolutional neural networks. *Med Phys*, 45(10), 4558-4567. <https://doi.org/10.1002/mp.13147>
- Tucker, S., Cevitanes, L. H., Styner, M., Kim, H., Reyes, M., Proffit, W., & Turvey, T. (2010). Comparison of actual surgical outcomes and 3-dimensional surgical simulations. *J Oral Maxillofac Surg*, 68(10), 2412-2421. <https://doi.org/10.1016/j.joms.2009.09.058>
- Van den Broeck, J., Vereecke, E., Wirix-Speetjens, R., & Vander Sloten, J. (2014). Segmentation accuracy of long bones. *Med Eng Phys*, 36(7), 949-953. <https://doi.org/10.1016/j.medengphy.2014.03.016>
- van Eijnatten, M., Rijkhorst, E. J., Hofman, M., Forouzanfar, T., & Wolff, J. (2016). The accuracy of ultrashort echo time MRI sequences for medical additive manufacturing. *Dentomaxillofac Radiol*, 45(5), 20150424. <https://doi.org/10.1259/dmfr.20150424>
- van Eijnatten, M., van Dijk, R., Dobbe, J., Streekstra, G., Koivisto, J., & Wolff, J. (2018). CT image segmentation methods for bone used in medical additive manufacturing. *Medical Engineering & Physics*, 51, 6-16. <https://doi.org/10.1016/j.medengphy.2017.10.008>
- Wallner, J., Hochegger, K., Chen, X., Mischak, I., Reinbacher, K., Pau, M., Zrnc, T., Schwenzer-Zimmerer, K., Zemann, W., Schmalstieg, D., & Egger, J. (2018). Clinical evaluation of semi-automatic open-source algorithmic software segmentation of the mandibular bone: Practical feasibility and assessment of a new course of action. *PLoS One*, 13(5), e0196378. <https://doi.org/10.1371/journal.pone.0196378>
- Wallner, J., Mischak, I., & Jan, E. (2019a). Computed tomography data collection of the complete human mandible and valid clinical ground truth models. *Sci Data*, 6, 190003. <https://doi.org/10.1038/sdata.2019.3>
- Wallner, J., Schwaiger, M., Hochegger, K., Gsaxner, C., Zemann, W., & Egger, J. (2019b). A review on multiplatform evaluations of semi-automatic open-source based image segmentation for cranio-maxillofacial surgery. *Comput Methods Programs Biomed*, 182, 105102. <https://doi.org/10.1016/j.cmpb.2019.105102>
- Weitz, J., Bauer, F. J., Hapfelmeier, A., Rohleder, N. H., Wolff, K. D., & Kesting, M. R. (2016). Accuracy of mandibular reconstruction by three-dimensional guided vascularised fibular free flap after segmental mandibulectomy. *Br J Oral Maxillofac Surg*, 54(5), 506-510. <https://doi.org/10.1016/j.bjoms.2016.01.029>

Zinser, M. J., Sailer, H. F., Ritter, L., Braumann, B., Maegele, M., & Zöller, J. E. (2013). A Paradigm Shift in Orthognathic Surgery? A Comparison of Navigation, Computer-Aided Designed/Computer-Aided Manufactured Splints, and "Classic" Intermaxillary Splints to Surgical Transfer of Virtual Orthognathic Planning. *Journal of Oral and Maxillofacial Surgery*, 71(12), 2151.e2151-2151.e2121. <https://doi.org/10.1016/j.joms.2013.07.007>

## 8 Danksagung

An erster Stelle möchte ich mich herzlichst bei Herrn PD Dr. Dr. Lucas M. Ritschl für die Konzeption und Überlassung der Arbeit bedanken. Insbesondere bedanke ich mich für die angenehme Betreuung, die Geduld und die stets konstruktive Zusammenarbeit.

Mein Dank gilt ebenfalls der gesamten Abteilung der Mund-Kiefer-Gesichtschirurgie des Klinikums rechts der Isar für die Ermöglichung der Durchführung der Datenerhebung und der Bereitstellung der Arbeitsplätze und -materialien.

Ebenso danke ich der Firma Kumovis für die Überlassung des Arbeitsplatzes und der Arbeitsmittel.

Vielen Dank auch an Moritz Medl für die tatkräftige Unterstützung bei der Datenerhebung.

Mein besonderer Dank gilt meiner Familie, meinen Freunden und meiner Freundin, die mir mit Rat und Tat zur Seite standen und mich in allen Situationen unterstützten.