

Automatische Detektion von Bombenkratern in Kriegsluftbildern mittels markierter Punktprozesse

CHRISTIAN KRUSE¹, HAJNALKA NEUBERGER², FRANZ ROTTENSTEINER¹, THORSTEN HOBERG³,
MARCEL ZIEMS³, JULIA HUTH³ & CHRISTIAN HEIPKE¹

Zusammenfassung: In diesem Beitrag wird eine Methode zur automatischen Detektion von Bombenkratern in Kriegsluftbildern aus dem 2. Weltkrieg vorgeschlagen. Hierbei wird das Objektmodell für die Bombenkrater durch Ellipsen repräsentiert. Mithilfe eines probabilistischen Ansatzes, basierend auf markierten Punktprozessen, wird die wahrscheinlichste Konfiguration von Objekten innerhalb der Szene bestimmt. Durch das Hinzufügen und Entfernen neuer Objekte zur bzw. von der aktuellen Konfiguration sowie Modifikationen der Ellipsenparameter werden zufällig neue Objektkonfigurationen erzeugt. Anschließend wird jede Konfiguration anhand einer Energiefunktion bewertet. Dabei werden hohe Gradientenmagnituden entlang des Ellipsenrandes favorisiert und überlappende Ellipsen bestraft. Das globale Optimum der Energie, welches die Übereinstimmung mit einem vordefinierten Modell beschreibt, liefert das Reversible Jump Markov Chain Monte Carlo Sampling in Kombination mit Simulated Annealing. Unsere Ergebnisse zeigen das generelle Potential der Methode zur automatischen Detektion von Bombenkratern in einem heterogenen Bildbestand auf.

1 Einleitung

Das Bundesland Niedersachsen war Ziel zahlreicher Luftangriffe der alliierten Streitkräfte während des zweiten Weltkriegs. Die Nachwirkungen dieser Angriffe sind bis heute präsent. Zahlreiche Blindgänger lagern noch immer im Erdreich. Insbesondere bei Erdarbeiten ist die Gefahr einer Detonation der Blindgänger gegeben, auch sind Vorfälle ohne äußere Einwirkung bekannt.

Eine zentrale Aufgabe des Kampfmittelbeseitigungsdienstes Niedersachsens ist die Auswertung von Kriegsluftbildern hinsichtlich Kriegsbelastungen, insbesondere der Identifikation von Bombenblindgängerverdachtspunkten. Hierzu werden Stereobildpaare einzeln ausgewertet. Dies bringt, trotz der Einschränkung auf besonders gefährdete oder anderweitig relevante Flächen, einen hohen Bearbeitungsaufwand mit sich. Zu einer verbesserten Prozesssteuerung und Dokumentation wird aktuell das Kampfmittelinformationssystem Niedersachsen (KISNi) aufgebaut, welches künftig zusätzliche Analysemöglichkeiten bieten wird. Für viele Fragestellungen ist es ausreichend, über flächendeckende Informationen hinsichtlich des grundsätzlichen Vorkommens von Kriegsbelastungen in Form von „Belastungskarten“ zu verfügen. Belastungskarten können erzeugt werden, wenn mit hoher Sicherheit ein großer

¹ Leibniz Universität Hannover, Institut für Photogrammetrie und GeoInformation, Nienburger Straße 1, D-30167 Hannover, E-Mail: [kruse, rottensteiner, heipke]@ipi.uni-hannover.de

² Budapest University of Technology and Economics, Department of Photogrammetry and Geoinformatics, Műegyetem rkp. 3, H-1111 Budapest, E-Mail: neuberger.hajnalka@epito.bme.hu

³ Landesamt für GeoInformation und Landesvermessung Niedersachsen, Podbielskistraße 331, D-30659 Hannover, E-Mail: [thorsten.hoberg, marcel.ziems, julia.huth]@lgin.niedersachsen.de

Prozentsatz sämtlicher Belastungen detektiert werden kann. Für die kosteneffiziente Erstellung einer solchen Belastungskarte ist eine automatische Erkennung von Hinweisen auf Kriegsbelastung, vor allem von Bombenkratern (Abb. 1), in Kriegsluftbildern unerlässlich.

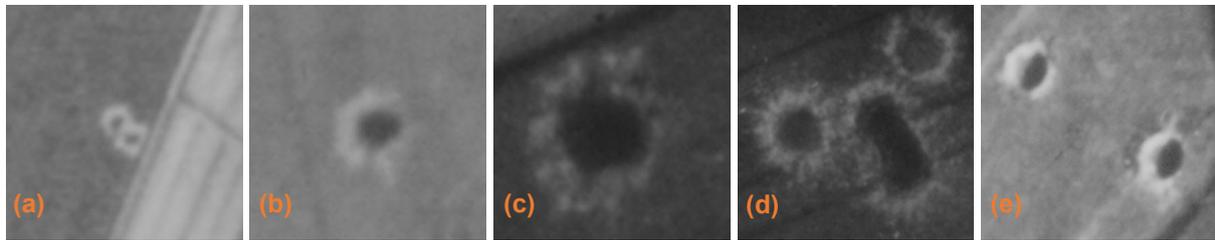


Abb. 1: Bombenkrater prägen sich in den Kriegsluftbildern aufgrund von (a-c) verschiedenen Maßstäben und Größen sowie (d, e) unterschiedlichem Aussehen verschiedenartig aus.

In der Bildanalyse werden für derartige Aufgaben immer häufiger probabilistische Modelle genutzt, bei welchen Vorwissen in Form von Wahrscheinlichkeiten integriert wird. Bekannte Ansätze stellen Markov Random Fields (GEMAN & GEMAN 1984) sowie Conditional Random Fields (KUMAR & HEBERT 2006) dar. Durch die Modellierung von Kontext kann Wissen über die Objekte im Bild integriert werden. Beispielsweise lassen sich auf diese Weise ähnliche Klassen für Pixel in einer lokalen Nachbarschaft begünstigen (LI 2009). Jedoch ist es schwierig, globalere Bedingungen der Objekte, wie beispielsweise hinsichtlich der Form, zu integrieren. Hier setzen markierte Punktprozesse (DALEY & VERE-JONES 2003; DESCOMBES & ZERUBIA 2002) an, welche ein starkes Objektmodell nutzen. Das Sampling liefert die global optimale Konfiguration an Objekten eines bestimmten Typs.

Die Integration von Modellwissen kann auf verschiedene Arten erfolgen. In der Regel werden einfache geometrische Primitive, die über eine geringe Anzahl an Parametern beschrieben werden können, zur Repräsentation der Objekte genutzt. Ein vielfach in der Literatur verwendetes Objekt sind Rechtecke, mit deren Hilfe z.B. Gebäude in der Szene extrahiert werden können. CHAI et al. (2012) nutzen hierfür einen kombinierten Ansatz aus Markov Random Fields und markierten Punktprozessen auf Basis von Satellitenbildern. Während auf der High-Level-Ebene Gebäude durch Rechtecke repräsentiert und in das Verfahren der markierten Punktprozesse integriert werden, wird auf der Low-Level-Ebene ein Markov Random Field genutzt, um das Aussehen der Gebäude mittels Farbhistogrammen zu modellieren. Gleichermaßen modellieren TOURNAIRE et al. (2010) und BREDIF et al. (2013) Objekte als Rechtecke im Zusammenhang mit markierten Punktprozessen. Die Datengrundlage bilden digitale Oberflächenmodelle, innerhalb derer die Rechtecke zufällig verteilt werden. Damit ein Rechteck in die Objektkonfiguration aufgenommen wird, müssen hohe Gradientenmagnituden der Höhen am Rechteckrand vorliegen. Ferner wird in diesem Modell gefordert, dass sich Rechtecke nicht überlappen dürfen. Anders als bei CHAI et al. (2012) sind starke Überlappungen nicht unmöglich, sondern unwahrscheinlich. Ziel dieser Formulierung ist es, starke Überlagerungen von Objekten zu vermeiden, wohingegen geringfügige Überlappungen wahrscheinlicher sind. Darüber hinaus werden Rechtecke verwendet, um Fassaden an Gebäuden auf Grundlage von rektifizierten Bildern zu interpretieren (WENZEL & FÖRSTNER 2016) oder Fahrzeuggruppen aus Laserscandaten zu extrahieren (BÖRCS & BENEDEK 2015). Bei ersterem Ansatz werden im Gegensatz zu den bisher genannten Verfahren die Statistiken von typischen

Konfigurationen der Fassadenobjekte (Fenster, Eingänge) mittels Trainingsdaten gelernt. Neben dieser Form von Objekten werden z.B. Zylinder zur Personendetektion in 3D (UTASI & BENEDEK 2011) und Verteilungsfunktionen zur Modellierung von Wellenformen (MALLET et al. 2010) genutzt. Ferner erlauben Segmente Linien-Netzwerke, wie Straßen oder Blutgefäße, zu extrahieren (LACOSTE et al. 2005; SUN et al. 2007). Darüber hinaus werden markierte Punktprozesse zur Detektion von Flamingos (DESCAMPS et al. 2008), Saatgutprodukten (DUBOSCLARD et al. 2014) und Planetenkratern (TROGLIO et al. 2010) herangezogen. In allen Fällen sind die Objekte durch Ellipsen modelliert. LAFARGE et al. (2010) verwenden verschiedenste Objektmodelle, welche eine große Flexibilität hinsichtlich verschiedenster Anwendungen ermöglichen. So werden z.B. Kreise, Rechtecke und Linien genutzt, um Baumkronen, Grundrisse von Gebäuden sowie Straßennetze aus Bildern zu extrahieren. Den Erhalt netzwerkartiger Strukturen, wie beispielsweise von Straßennetzen, erlauben Verfahrensweisen auf Basis von Graphen, da jeder Knoten entweder zu einem Kreuzungs- oder Endpunkt gehört. SCHMIDT et al. (2016) nutzen diese graphenbasierte Repräsentation um Flussnetzwerke in digitalen Geländemodellen zu finden.

Die aufgeführten Beiträge zeigen das Potential stochastischer Modelle basierend auf markierten Punktprozessen in verschiedensten Anwendungsfeldern der Bildanalyse auf. Neben der Bestimmung der global optimalen Objektkonfiguration profitieren sie von ihrer Flexibilität hinsichtlich der Integration von Wissen über die Objekte und deren Beziehung zu anderen Objekten. Darüber hinaus ist die Anzahl an Objekten in der Szene während des Samplings variabel. Wir wollen diese Vorteile nutzen, um Bombenkrater in Kriegsluftbildern zu detektieren. Das hierbei genutzte Modell sind Ellipsen, deren Konfiguration während des Samplings optimiert wird. Zur Bewertung der Objektkonfiguration werden hohe Magnituden der Grauwertgradienten am Ellipsenrand favorisiert und die Überlappung von Ellipsen bestraft. Im Folgenden werden zunächst die mathematischen Grundlagen der stochastischen Optimierung mithilfe von markierten Punktprozessen beschrieben (Abschnitt 2). In Abschnitt 3 stellen wir das Modell vor, welches zur Detektion der Bombenkrater genutzt werden soll. Daraufhin werden Experimente und Ergebnisse auf Grundlage von Kriegsluftbildern gezeigt (Abschnitt 4). Abschließend werden in Abschnitt 5 eine Zusammenfassung und ein Ausblick für künftige Arbeiten gegeben.

2 Mathematische Grundlagen

2.1 Markierte Punktprozesse

Punktprozesse (für Details sei auf DALEY & VERE-JONES (2003) und DESCOMBES (2013) verwiesen) gehören zu den stochastischen Prozessen und ermöglichen die mathematische Beschreibung von Zufallsgeschehen. Anders als bei einem deterministischen Ansatz erfolgt die Modellierung in Form von Wahrscheinlichkeiten. Es existieren verschiedene Arten von Punktprozessen, wobei die Realisierung des Punktprozesses aus isolierten Punkten in einem mathematischen Raum besteht. Der Parameterraum weist hierbei häufig einen zeitlichen oder räumlichen Bezug auf. In letzterem Fall wird von einem räumlichen Punktprozess gesprochen, welcher die Grundlage der Verfahren zur Extraktion von Objekten in Fernerkundungsdaten bildet und somit auch bei uns Anwendung findet.

Punktprozesse haben die Aufgabe, aus oftmals großen Datenmengen die wahrscheinlichste Konfiguration von Objekten eines bestimmten Typs zu finden, welche ein beobachtetes Phänomen am besten charakterisiert. Sie bieten die Möglichkeit, eine Szene mittels einer ungeordneten Menge an Punkten innerhalb einer begrenzten Region $F \subset R^k$ zu beschreiben (bei uns ist $k = 2$). Dabei ist ein Punkt über seine Position $p_i = (x_i, y_i)$ charakterisiert. Da häufig Punkte allein eine Szene nur schwer beschreiben können, wurden Ansätze entwickelt, die jeden Punkt um zusätzliche Parameter m_i erweitern. Auf diese Weise kann der Punkt mit einem geometrischen Objekt $u_i = (p_i, m_i)$ in Verbindung gebracht werden: das Objekt u_i wird durch die Position p_i fixiert (oft der Massenmittelpunkt) und die Merkmale m_i , welche sich von Punkt zu Punkt verschieden ausprägen können, enthalten weitere Informationen zum Objekt. Durch das Hinzufügen von Objektparametern zu jedem Punkt entsteht ein markierter Punktprozess, welcher als ein stochastisches Modell von Konfigurationen einer unbekannt Anzahl von Objekten des Typs $u_i = (p_i, m_i)$ in F aufgefasst werden kann.

Das Modell des homogenen Poisson-Punktprozesses, welcher als grundlegender Punktprozess aufgefasst werden kann, nimmt eine rein zufällige Verteilung von Objekten im Raum an. Ferner stehen die Objekte in keiner Beziehung zueinander. Die Wahrscheinlichkeit $P_\lambda(n)$ für die Anzahl der Objekte n folgt einer diskreten Poisson-Verteilung

$$P_\lambda(n) = \frac{\lambda(F)^n}{n!} \cdot e^{-\lambda(F)}. \quad (1)$$

Der Parameter λ beschreibt dabei die erwartete Anzahl an Objekten innerhalb von F und wird häufig als Intensitätsparameter bezeichnet. Die Wahrscheinlichkeit für die Positionen der Objekte folgt einer Gleichverteilung und die Objekte sind stochastisch unabhängig in F verteilt. In der Praxis trifft die Annahme einer völligen Zufälligkeit häufig nicht zu, da Abhängigkeiten zwischen den Objekten bestehen. Es werden komplexere Modelle gefordert, mit welchen die Qualität der Objektkonfiguration gemessen werden kann. Hierfür kann eine Wahrscheinlichkeitsdichte $h(\cdot)$ des markierten Punktprozesses formuliert werden. Erreicht werden kann dies mit Bezug auf einen Referenz-Punktprozess, welcher üblicherweise als Poisson-Punktprozess definiert ist.

In unserem Ansatz wird $h(\cdot)$ durch eine Gibbs-Energie $U(\cdot)$ in der Form $h \propto \exp - U(\cdot)$ ausgedrückt. Die Gibbs-Energie setzt sich aus zwei Teilen, der Daten- und der Priorenergie, zusammen. Der relative Einfluss kann durch einen Parameter $\beta \in [0, 1]$ modelliert werden, um eine den Daten angepasste Gewichtung vornehmen zu können

$$U(\cdot) = \beta \cdot U_D(\cdot) + (1 - \beta) \cdot U_P(\cdot). \quad (2)$$

Hierbei entspricht $U_D(\cdot)$ der Datenenergie, welche die Kongruenz der Objektkonfiguration mit den Eingangsdaten vergleicht. Interaktionen zwischen den Objekten werden innerhalb von $U_P(\cdot)$ berücksichtigt. Die optimale Objektkonfiguration $u^* = \{u_1, \dots, u_n\}$ kann bestimmt werden, indem die Wahrscheinlichkeitsdichte $h(\cdot)$ maximiert wird, also $u^* = \arg \max h(\cdot)$. Diese Vorgehensweise entspricht ebenfalls der Konfiguration, welche die Gibbs-Energie $U(\cdot)$ minimiert, das heißt $u^* = \arg \min U(\cdot)$. Nun ist die Wahrscheinlichkeitsdichte $h(\cdot)$ in der Regel multi-modal und darüber hinaus in einem Konfigurationsraum definiert, welcher eine variable Dimension besitzt. Aus diesem Grund wird zum Schätzen des globalen Minimums

häufig ein Reversible Jump Markov Chain Monte Carlo Sampler in Kombination mit Simulated Annealing verwendet, um eine Approximation von u^* zu finden.

2.2 Reversible Jump Markov Chain Monte Carlo Verfahren

Mithilfe von Markov-Ketten (z.B. ANDRIEU et al. 2003) können zufällige Zustandsänderungen eines Systems modelliert werden. Der Poisson-Prozess (Abschn. 2.1) stellt ein Beispiel einer Markov-Kette dar, in welchem die Anzahl der Objekte der Poisson-Verteilung (1) folgt. Die Ketten besitzen die Markov-Eigenschaft, welche besagt, dass die Zukunft eines stochastischen Prozesses unabhängig von der Vergangenheit bei gegebenem gegenwärtigen Zustand ist. Das heißt, in einer Sequenz von Zuständen besitzt jede Stichprobe X_t eine Wahrscheinlichkeitsverteilung, die nur vom vorherigen Wert X_{t-1} abhängt.

Markov Chain Monte Carlo Methoden (METROPOLIS et al. 1953; HASTINGS 1970) können nicht mit Zustandsräumen verschiedener Dimensionen umgehen. Hier setzen die Reversible Jump Markov Chain Monte Carlo (RJCMC) Verfahren an, welche die Modellierung von Szenen mit einer unbekannt Anzahl an Objekten sowie Änderungen der Dimension der Parameter zwischen zwei Sampling-Schritten erlauben. Diese Erweiterung wurde erstmals von GREEN (1995) vorgeschlagen und wird durch die Definition einer Menge an Bewegungen bzw. Änderungen, den sogenannten reversiblen Sprüngen (*reversible jumps*), erreicht. Reversibilität bedeutet, dass es möglich ist, jede Änderung rückgängig zu machen, sodass man immer zu einem früheren Zustand zurückkehren kann. In jeder Iteration t schlägt der Sampler eine Änderung der aktuellen Objektkonfiguration aus jener vordefinierten Menge an Bewegungen (*jumps*) vor. Dabei existiert zu jeder Art der Änderung eine Dichtefunktion Q_m , welche auch als Kernel (Kern) bezeichnet wird. Dieser Prozess führt von einer Objektkonfiguration X_t zu einer neuen Konfiguration X_{t+1} gemäß einer Wahrscheinlichkeit $Q_m(X_t \rightarrow X_{t+1})$. Die Startkonfiguration X_0 kann aufgrund der Eigenschaften der Markov-Ketten (TIERNEY 1996) zufällig gewählt werden. Die Änderung bzw. neue Konfiguration wird mit einer gewissen Akzeptanzwahrscheinlichkeit α , die von der Energievariation zwischen X_t und X_{t+1} abhängt, angenommen

$$\alpha = \min \left(1, \frac{Q_m(X_{t+1} \rightarrow X_t)}{Q_m(X_t \rightarrow X_{t+1})} \cdot \exp - \left(\frac{U(X_{t+1}) - U(X_t)}{T_t} \right) \right). \quad (3)$$

In (3) beschreibt das Kernel-Verhältnis $Q_m(X_{t+1} \rightarrow X_t)/Q_m(X_t \rightarrow X_{t+1})$ das Verhältnis der Wahrscheinlichkeiten für die Änderung der Konfiguration von X_{t+1} zu X_t und umgekehrt. $U(X_{t+1})$ und $U(X_t)$ sind die Gibbs-Energie (2) der neuen bzw. aktuellen Objektkonfiguration und T_t bezeichnet die Temperatur des Simulated Annealing der Iteration t , welche in Abschnitt 2.3 beschrieben wird.

2.3 Simulated Annealing

Um das Optimum der Energie zu finden, wird das RJCMC Verfahren mit Simulated Annealing kombiniert. Der Algorithmus bildet den Abkühlungsprozess von Stoffen in der Festkörperphysik nach und lässt sich auf das heuristische Optimierungsverfahren des Simulated Annealing übertragen (METROPOLIS et al. 1953; KIRKPATRICK et al. 1983). Die Temperatur entspricht einer Wahrscheinlichkeit, mit der sich ein Zwischenergebnis der Optimierung auch verschlechtern darf. Wesentlicher Vorteil hiervon ist, dass ein lokales Optimum wieder verlassen werden kann.

T_t strebt mit zunehmender Iteration gegen Null, während t gegen unendlich strebt. Zu Beginn des Algorithmus, wenn die Temperatur hoch ist, ist das Verfahren nicht selektiv. Bei abnehmender Temperatur wird der Prozess selektiver, das heißt Konfigurationen mit einer hohen Wahrscheinlichkeitsdichte werden bevorzugt. Der Abkühlungsprozess kann über eine logarithmische Abnahme realisiert werden, welche theoretisch Konvergenz zum globalen Optimum für jede beliebige Anfangskonfiguration X_0 gewährleistet. Aufgrund der hohen Berechnungszeiten wird in der Praxis üblicherweise ein schnelleres geometrisches Schema zur Abkühlung verwendet. Dieses liefert ein approximatives Resultat, welches nahe an der optimalen Lösung liegt (SALAMON et al. 2002; VAN LAARHOVEN & AARTS 1987).

3 Methodik

In dieser Arbeit werden Bombenkrater als Ellipsen modelliert. Mithilfe eines markierten Punktprozesses soll die optimale Konfiguration von solchen Objekten in der Szene gefunden werden. Dabei wird eine globale Energiefunktion minimiert, deren Optimierung iterativ durch das RJMCMC Sampling in Kombination mit Simulated Annealing erfolgt (Abschn. 2.2, 2.3). Während des Optimierungsprozesses verändert sich die Objektkonfiguration kontinuierlich und wird basierend auf der Übereinstimmung mit einem vordefinierten Modell evaluiert. Wir favorisieren in diesem Modell hohe Gradientenmagnituden entlang des Ellipsenrandes und bestrafen sich überlappende Ellipsen.

Im ersten Schritt wird das Objektmodell formuliert, welches die Bombenkrater im Bild repräsentiert (Abschn. 3.1). In Abschnitt 3.2 werden die möglichen Änderungen der Objektkonfiguration eingeführt. Nachfolgend wird die Energiefunktion definiert, die es während des Samplings zu minimieren gilt (Abschn. 3.3). Abschließend wird in Abschnitt 3.4 eine Methode zur Einschränkung des Suchbereiches im Bild beschrieben, die dem Verfahren der markierten Punktprozesse vorangestellt wird.

3.1 Objektmodell

Das für die Detektion der Bombenkrater verwendete Modell besteht aus einem markierten Punktprozess von Ellipsen. Wie beispielsweise bei PERRIN et al. (2006) wird jede Ellipse über ihre zweidimensionale Position $P(x, y)$ und drei Merkmale $M(a, b, \theta)$ beschrieben. Das resultierende 5-Tupel (x, y, a, b, θ) nimmt im Zustandsraum Z die Werte

$$Z = P \times M = [0, X] \times [0, Y] \times [a_m, a_M] \times [b_m, b_M] \times [0, \pi[\quad (4)$$

an. Hierbei sind (x, y) die Koordinaten des Ellipsenzentrums, X und Y repräsentieren die Breite und Höhe des Bildes. Der minimale und maximale Wert der großen bzw. kleinen Halbachse wird durch $[a_m, a_M]$ bzw. $[b_m, b_M]$ begrenzt. Die Orientierung der Ellipsen wird über den Winkel $\theta \in [0, \pi[$ beschrieben, welche im Uhrzeigersinn relativ zur positiven x-Achse definiert ist (Abb. 2). Wir fordern $a \geq b$.

3.2 Änderungen der Objektkonfiguration

Um eine optimale Objektkonfiguration zu finden, wird die Konfiguration aus Ellipsen generiert und den Daten iterativ durch ein RJMCMC Sampling in Kombination mit dem Simulated

Annealing angepasst. Die Methode stellt vier Änderungsarten der Konfiguration bereit, wobei die Modifikationen mithilfe zugehöriger Kernel ermöglicht werden. Zum einen erlauben *Geburts- und Todes-Kernel*, Q_B bzw. Q_D , mit zugehöriger Vorschlagswahrscheinlichkeit $p_{Q_B} = p_{Q_D}$, das Hinzufügen bzw. Entfernen eines Objektes zur bzw. von der aktuellen Objektkonfiguration. Für den Fall einer Geburt (Abb. 3a) werden die Position, Orientierung und zwei Halbachsen einer neuen Ellipse gemäß (4) generiert. Für jeden Parameter wird eine Gleichverteilung angenommen. Beim Todesevent wird eine zufällig gewählte Ellipse aus der bestehenden Objektkonfiguration entfernt (Abb. 3b). Das Kernel-Verhältnis aus Gleichung (3) berücksichtigt die Wahrscheinlichkeit für die Änderung der Konfiguration von X_t zu X_{t+1} und umgekehrt. Wie SCHMIDT et al. (2016) modellieren wir das Kernel-Verhältnis des Geburtsereignisses durch

$$\frac{Q_{BD}(X_{t+1} \rightarrow X_t)}{Q_{DB}(X_t \rightarrow X_{t+1})} = \frac{p_D}{p_B} \cdot \frac{\lambda}{n}, \quad (5)$$

wobei p_B und p_D der Wahrscheinlichkeit für die Auswahl eines Geburts- bzw. Todesevents entsprechen. Die aktuelle Anzahl an Ellipsen innerhalb der Objektkonfiguration wird durch n repräsentiert und der Poisson-Parameter λ beschreibt die erwartete Anzahl an Objekten im Bild. Beim Todesereignis entspricht das Kernel-Verhältnis der inversen Geburtsrate.

Darüber hinaus können die Parameter eines Objektes einer Konfiguration modifiziert werden. Mithilfe des *Translations-Kernels* Q_T wird eine zufällig gewählte Ellipse von ihrer aktuellen Position verschoben. Hierfür wird zufällig ein Verschiebungsvektor in der lokalen Nachbarschaft auf Basis eines vorgegebenen Intervalls generiert (Abb. 4a). Die drei Merkmale der Ellipse lassen sich durch den *Merkmalsvariations-Kernel* Q_M verändern. Hierfür wählen wir zufällig eine Ellipse aus der aktuellen Konfiguration aus, von welcher die kleine und große Halbachse sowie die Orientierung innerhalb vordefinierter Schwellwerte modifiziert werden (Abb. 4b). Diesen beiden Änderungsarten sind die Vorschlagswahrscheinlichkeiten p_{Q_T} bzw. p_{Q_M} zugehörig. Sowohl für die Translation als auch für die Merkmalsvariation wird das Kernel-Verhältnis auf 1 gesetzt

$$\frac{Q_T(X_{t+1} \rightarrow X_t)}{Q_T(X_t \rightarrow X_{t+1})} = \frac{Q_M(X_{t+1} \rightarrow X_t)}{Q_M(X_t \rightarrow X_{t+1})} = 1. \quad (6)$$

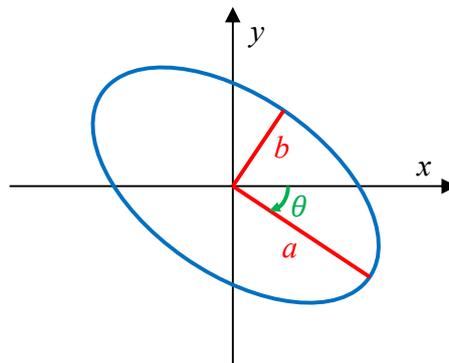


Abb. 2: Unser Objektmodell ist eine Ellipse, welche über ihre Position (x, y) und drei Merkmale (a, b, θ) beschrieben wird.

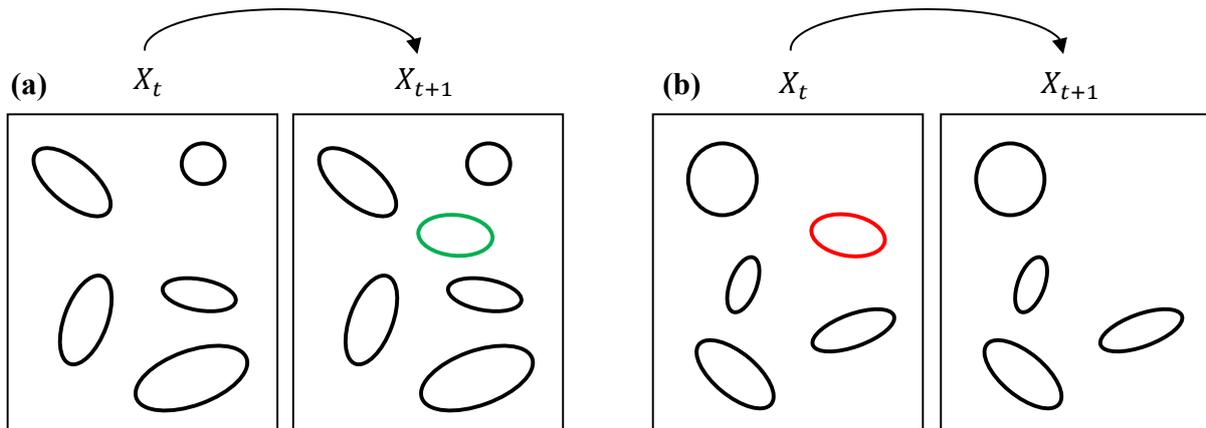


Abb. 3: Funktionsweise zweier Kernel, welche das Hinzufügen und Entfernen von Ellipsen zur bzw. von der Objektkonfiguration verdeutlichen.

- (a) *Geburts-Kernel*: Die neue Objektkonfiguration X_{t+1} wird um eine Ellipse (grün) erweitert.
- (b) *Todes-Kernel*: Aus der aktuellen Objektkonfiguration X_t wird eine Ellipse (rot) entfernt.

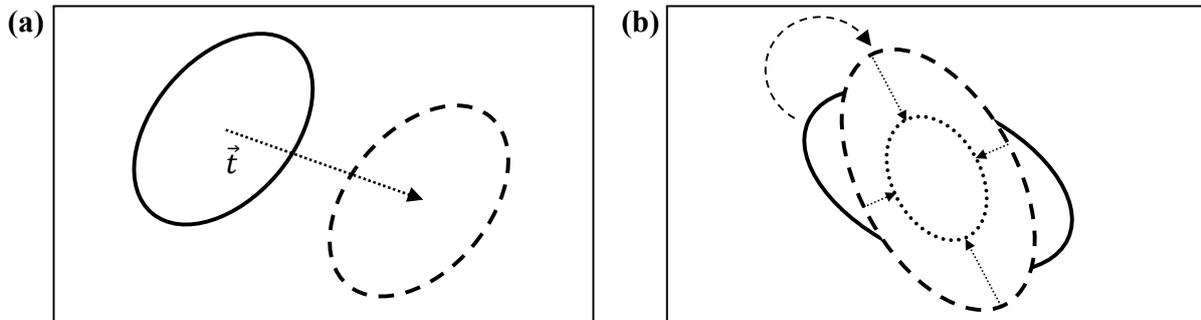


Abb. 4: Funktionsweise zweier Kernel, welche Änderungen an den Parametern des Objektes ermöglichen.

- (a) *Translations-Kernel*: Die Position der Ellipse wird um den Verschiebungsvektor \vec{t} verschoben.
- (b) *Merkmalsvariations-Kernel*: Die Merkmale der Ellipse, also die Orientierung und die Halbachsen, werden verändert.

3.3 Energiefunktion

In jedem Iterationsschritt wird die aktuelle mit der neuen Objektkonfiguration auf Basis der Gibbs-Energie (2) verglichen. Diese beschreibt die Übereinstimmung der Konfiguration mit einem vordefinierten Modell für die Bombenkrater. Ziel des Samplings ist es, diejenige Konfiguration zu finden, für welche die Gibbs-Energie minimal ist. In unserem Fall setzt sich die Gibbs-Energie aus zwei Teilen zusammen, der Daten- und der Priorenergie.

3.3.1 Datenenergie

Die Datenenergie $U_D(X_t)$ aus Gleichung (2) beschreibt die Übereinstimmung der Objektkonfiguration mit den Eingangsdaten. Bombenkrater sind durch überwiegend lokal dunklere Grauwerte im Vergleich zur Umgebung gekennzeichnet. Maßgeblich hierfür ist der durch die Sonne hervorgerufene Schattenwurf, dessen Form sich innerhalb der Krater hauptsächlich ellipsenförmig ausprägt (Abb. 1). Eine neu erzeugte oder veränderte Ellipse führt

zu einer Verminderung der Datenenergie, wenn entlang der Ränder der Ellipse vergleichsweise höhere Gradientenmagnituden auftreten, das Modell der Ellipse also besser zu dem erwarteten Schattenwurf passt. Wir bestimmen die Gradienten entlang des Ellipsenrandes ähnlich SCHMIDT et al. (2016) durch

$$U_D(X_t) = \sum_{e_j \in X_t} \left(c - \sum_{l_j=1}^{64} \frac{1}{n_j} \sum_{p_j=1}^{n_j} \nabla_{IMG_{p_j}}^b \right). \quad (7)$$

In Gleichung (7) ist $\nabla_{IMG_{p_j}}^b$ die Komponente des Grauwertgradienten am Randpixel p_j in Richtung des Normalenvektors der Ellipse e_j (Abb. 5). Zur Berechnung der Summe der gleichgewichteten Gradienten entlang des Ellipsenrandes werden n_j Pixel p_j herangezogen. Der Rand der Ellipse wird durch ein Polygon mit einer konstanten Anzahl von zurzeit 64 Punkten, welche durch Linien $l_j \in \{1, 2, \dots, 64\}$ miteinander verbunden sind, approximiert. In zukünftigen Untersuchungen könnte z.B. die Anzahl der Punkte, die den Ellipsenrand repräsentieren, abhängig von der Bildmaßstabszahl und von den in der Szene zu erwartenden Bombenkratergrößen automatisch gewählt werden. Ferner könnten Ellipsen, insbesondere solche, bei denen die große Halbachse deutlich kürzer als die kleine Halbachse ist, in Bereichen hoher Krümmung durch vergleichsweise mehr Punkte approximiert werden. Eine Konstante $c \geq 0$ sorgt dafür, dass die Energie nur minimiert wird, falls die Summe in Gleichung (7) oberhalb eines vorgegebenen Wertes liegt.

3.3.2 Priorenergie

Mithilfe der Priorenergie können bestimmte Konfigurationen auf Basis von Vorwissen favorisiert werden. Um die Ansammlung von vielen Objekten in Regionen mit niedriger Datenenergie zu vermeiden, werden Konfigurationen bestraft, in denen sich Ellipsen überlappen. Da sich Bombenkrater in der Regel nicht oder nur in geringem Maße überlappen, lassen wir in der Formulierung des Priorterms eine gewisse Überlappung zu, eine starke Überlappung wird jedoch vermieden. Zur Berechnung der Energie werden wie bei PERRIN et al. (2005) alle möglichen Kombinationen von sich überlappenden Ellipsenpaaren e_i, e_j herangezogen und jeweils die Überlappungsfläche A_{ij} der Ellipsen e_i und e_j sowie die zugehörigen relativen Überlappungsflächen $A_{ij}/A_i(e_i)$ und $A_{ij}/A_j(e_j)$ berechnet (Abb. 6). Für die Priorenergie folgt

$$U_P(X_t) = f \cdot \sum_{e_i, e_j} \max\left(\frac{A_{ij}}{A_i(e_i)}, \frac{A_{ij}}{A_j(e_j)}\right), \quad (8)$$

wobei sich in (8) die Stärke der Bestrafung mithilfe eines konstanten Faktors f gewichten lässt.

3.4 Einschränkung des Suchbereiches

Dem Verfahren der markierten Punktprozesse wird eine Methode zur Einschränkung des Suchbereiches im Bild vorangestellt. Aufgrund der Bildgrößen von ca. 5000 x 5000 Pixeln und mehr ist dieser Schritt sinnvoll, um den Rechenaufwand beim Sampling zu reduzieren. So nutzen beispielsweise ZHANG et al. (2014), ebenfalls im Zusammenhang mit markierten Punktprozessen, ein Baumkronendachmodell zur Suchraumeinschränkung. Innerhalb dieser Arbeit wird vorab ein Blob-Detektor angewandt (MALLICK 2015). Ein Blob ist eine Gruppe

zusammenhängender Pixel, die eine oder mehrere gemeinsame Eigenschaften (z.B. ähnliche Grauwerte) teilen. Ziel der Blob-Detektion ist es, diese Pixelregionen im Bild zu finden und zu markieren.

Im ersten Schritt der Blob-Detektion erfolgt eine Schwellwertbildung, bei welcher das Bild in mehrere Binärbilder konvertiert wird. Beginnend bei einem minimalen Schwellwert B_{S_min} wird dieser mittels eines Parameters für die Schrittweite B_{S_step} erhöht, sodass sich für den ersten Schwellwert B_{S_min} , für den zweiten $B_{S_min} + B_{S_step}$, für den dritten $B_{S_min} + 2 \cdot B_{S_step}$, usw. ergibt, bis ein maximaler Schwellwert B_{S_max} erreicht ist. Anschließend werden Zusammenhangskomponenten aus jedem Binärbild extrahiert und deren Zentren berechnet. Die Zentren werden in Abhängigkeit ihrer Koordinaten gruppiert, dabei bilden benachbarte Zentren eine Gruppe bzw. einen Blob. In diesem Zusammenhang stellt das Verfahren einen weiteren Parameter B_D bereit, welcher Blobs verschmelzen lässt, deren Distanz kleiner als B_D ist. Abschließend werden ausgehend von den Gruppen die finalen Zentren und Radien der Blobs bestimmt. Das Verfahren stellt zusätzlich zahlreiche Filtermöglichkeiten bereit. So lassen sich Blobs nach ihrer Rundheit B_R , Konvexität B_K und dem Trägheitsverhältnis B_T filtern. Für jede Größe stehen zwei Parameter, die untere und obere Grenze, definiert im Intervall $[0, 1]$, zur Verfügung. Hierbei stehen Werte nahe Eins für eine kreisähnliche Form. Ebenfalls ist es möglich, nur Blobs einer gewissen Pixelanzahl B_P zu erkennen, die sich zwischen einem minimalen und maximalen Wert bewegt. Ferner erlaubt das Verfahren, ausschließlich dunkle, helle oder beide Arten von Blobs zu detektieren.

Unser Ziel ist es, mithilfe des Blob-Detektors möglichst alle Bombenkrater zu erkennen, wenn auch um den Preis zahlreicher Fehldetektionen. Basierend auf diesen Ergebnissen können im Sampling-Prozess neue Objekte nur noch an denjenigen Positionen zufällig generiert werden, an denen bereits ein Blob detektiert wurde. Im Falle einer Geburt wird die Ellipse zunächst mit den Parametern des zugehörigen Blobs initialisiert. Somit werden potentielle Geburtsorte in Gleichung (4) nicht mehr durch die Breite und Höhe des Bildes beschränkt, sondern sind nur noch an Blob-Orten möglich. Die Ausgangskonfiguration besteht aus einer leeren Menge von Objekten.

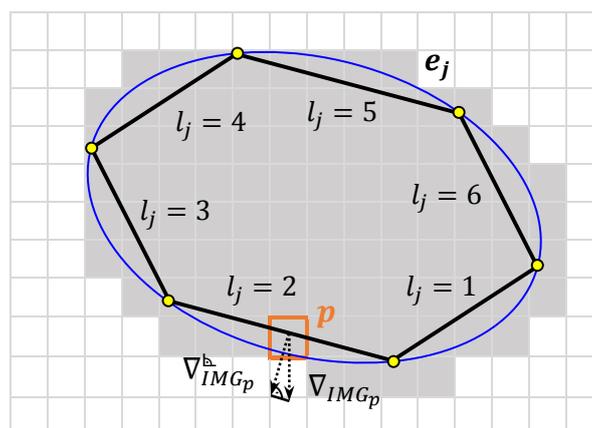


Abb. 5: Zur Berechnung des Datenterms berücksichtigen wir für jedes Pixel p des Ellipsenrandes (hier durch 6 Punkte approximiert, d.h. $l_j \in \{1, 2, \dots, 6\}$) die Summe der Komponenten der Gradienten $\nabla_{IMG_p}^b$ in Richtung des Normalenvektors. Graue Pixel kennzeichnen die aufgrund des Schattenwurfs zu erwartende dunkle Fläche innerhalb eines Bombenkraters im Bild.

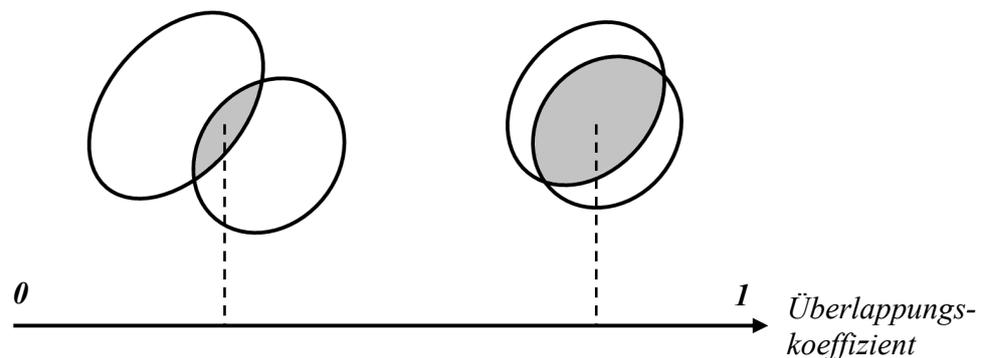


Abb. 6: Der Priorterm bestraft überlappende Objektkonfigurationen abhängig von ihrer relativen Überlappungsfläche. Je größer die gemeinsame Fläche, desto höhere Werte nimmt die Priorenergie an.

4 Experimente

4.1 Testdaten

Die Analysen unserer Methode erfolgen auf Grundlage von mit 1200 dpi gescannten panchromatischen Kriegsluftbildern mit 8-bit radiometrischer Auflösung aus dem zweiten Weltkrieg, welche vom Landesamt für Geoinformation und Landesvermessung Niedersachsen (LGLN) bereitgestellt wurden. Die Bilder verfügen über Bildmaßstabszahlen kleiner 15.000, sodass sich eine Bodenauflösung von ca. 0,3 m und besser ergibt. Zu Testzwecken werden drei Ausschnitte von Luftbildern aus Lemwerder, einer Gemeinde bei Bremen (Datensatz 1 und 2) sowie der Stadt Hannover (Datensatz 3) herangezogen. Innerhalb dieser Bildausschnitte herrschen unterschiedliche Beleuchtungssituationen und Bildinhalte vor. Der Schwerpunkt der Untersuchungen bzw. Entwicklungen liegt auf ländlichen Bereichen, weil in dicht bebauten Gebieten Bombenkrater durch den Schutt der zerstörten Gebäude verdeckt werden.

4.2 Parametereinstellungen

Die Parameterwahl wurde für unsere Experimente empirisch durchgeführt. Wird nicht gesondert darauf hingewiesen, sind die Parameter für die drei Bildausschnitte identisch gesetzt. Zunächst werden die Parameter des Blob-Detektors (Abschn. 3.4) auf $B_{S,min} = 10$, $B_{S,max} = 245$ und $B_{S,step} = B_D = 5$ gesetzt. Durch diese Wahl von $B_{S,min}$ werden Bildfehler, die sich in der Regel sehr dunkel im Bild ausprägen, nicht detektiert. Da Bombenkrater bzw. deren Schattenwürfe im Bild im Allgemeinen durch dunklere Grauwerte als die in ihrer Umgebung gekennzeichnet sind, soll das Verfahren nur dunkle Blobs erkennen. Vor dem Hintergrund, möglichst alle Bombenkrater im Bild zu detektieren, werden die Parameter zur Filterung mit $B_R \in \{0.1, 1\}$, $B_K \in \{0.4, 1\}$ und $B_T \in \{0.1, 1\}$ in der Form gesetzt, dass die Krater in ihrer Erscheinung durchaus von einem Kreis abweichen können. Auch wenn dies viele Fehldetektionen zur Folge hat, haben Experimente gezeigt, dass eine beschränkendere Parameterwahl die Detektion vieler Bombenkrater im Vorhinein ausschließen würde. Gleichmaßen ist es durch die Wahl von B_P im Intervall $[64, 4900]$ möglich, Bombenkrater einer sehr unterschiedlichen Pixelanzahl und

damit unterschiedlicher Größe zu detektieren. Dies ist notwendig, da die Größe der Bombenkrater in Abhängigkeit von der Bildmaßstabszahl stark variiert.

Im Zusammenhang mit den markierten Punktprozessen gewichten wir die Daten- und Priorenergie gleichermaßen, sodass der Parameter aus Gleichung (2) auf $\beta = 0.5$ gesetzt wird. Weiterhin wird beim Simulated Annealing ein geometrisches Schema zur Abkühlung genutzt, indem die Temperatur T_t aus Gleichung (3) mithilfe eines Faktors f_T in der Form $T_t = T_0 \cdot f_T^t$ verringert wird. Hierbei setzen wir die Starttemperatur $T_0 = 100$ und $f_T = 0.999994$. Die untere und obere Grenze der beiden Ellipsenhalbachsen (4) ergibt sich aus dem minimal und maximal im Bild vorhandenen Blob-Radius $B_r \in \{B_{r_min}, B_{r_max}\}$ zu $B_{r_min} = a_m = b_m$ bzw. $B_{r_max} = a_M = b_M$. Die Vorschlagswahrscheinlichkeiten der Kernel aus Abschnitt 3.2 werden auf $p_{Q_B} = p_{Q_D} = 0.05$ und $p_{Q_T} = p_{Q_M} = 0.45$ gesetzt. Die Wahrscheinlichkeit für die Auswahl eines Geburtsevents ($p_B = 0.05$) liegt deutlich unterhalb der für die Auswahl eines Todesevents mit $p_D = 0.95$ (Gleichung 5), da viele der bei der Blob-Detektion erzeugten potentiellen Krater in Wirklichkeit keinem Bombenkrater entsprechen. Auf diese Weise lassen sich die Berechnungen beschleunigen. Der Poisson-Parameter λ aus den Gleichungen (1) und (5) hängt von der erwarteten Anzahl an Objekten im Bild ab und wird für die Datensätze 1 und 2 auf $\lambda = 20$, für Datensatz 3 auf $\lambda = 40$ gesetzt. Ferner setzen wir den Parameter c für die ersten beiden Datensätze auf $c = 100$, für Datensatz 3 auf $c = 200$ (Gleichung 7), da sich die Grauwertgradienten unterschiedlich stark in den Bildern ausprägen. In Anlehnung an die Formulierungen aus Abschnitt 3.3.2 wählen wir den Faktor $f = 1000$ (Gleichung 8), da hierdurch Überlappungen von Objekten in geringem Maße möglich bleiben.

4.3 Ergebnisse

Die optimale Objektkonfiguration wird durch das Hinzufügen bzw. Entfernen von Ellipsen oder deren Parametervariation iterativ erzeugt (Abb. 7c-e). Ausgehend von den Ergebnissen des Blob-Detektors (Abb. 7b, rote Kreise) sind im Sampling-Prozess nur noch Geburten an Positionen möglich, an denen bereits ein Blob detektiert wurde. Untersuchungen haben gezeigt, dass die Möglichkeit von Geburten außerhalb dieser Blob-Orte bei ähnlichen Ergebnissen zu höheren Laufzeiten führt. Neben einigen falschen Detektionen (Abb. 7e, rote Ellipsen) werden bis auf zwei Bombenkrater (Abb. 7e, blaue Pfeile) alle gefunden.

Abbildung 8 zeigt die Ergebnisse für die Datensätze 2 und 3. Auffällig für den dritten Datensatz ist, dass trotz der zahlreichen falschen Detektionen des Blob-Detektors (Abb. 8e) viele dieser durch das Verfahren der markierten Punktprozesse eliminiert werden (Abb. 8f). Um die Ergebnisse zu evaluieren, wurden manuell flächenhafte Referenzdaten für die Bombenkrater erzeugt. Die Evaluierung erfolgt dabei gesondert für die Ergebnisse des Blob-Detektors und die der markierten Punktprozesse. Liegt ein Blob- bzw. Ellipsenmittelpunkt innerhalb der Referenzfläche eines Bombenkraters, so wird der Blob bzw. die Ellipse als korrekt definiert. Die Korrektheit ist somit der prozentuale Anteil an Blob- bzw. Ellipsenmittelpunkten, die innerhalb der Referenzfläche liegen. Die Vollständigkeit der Objektkonfiguration ist der prozentuale Anteil an Bombenkratern, der durch die jeweilige Methode gefunden wurde. Die Ergebnisse in Tabelle 1 zeigen, dass mithilfe des Blob-Detektors eine mittlere Vollständigkeit von 93 % erreicht werden kann, jedoch liegt die Korrektheit mit ca. 34 % deutlich unterhalb des Wertes für die Vollständigkeit. Das hier vorgestellte Verfahren auf Basis von markierten Punktprozessen

erhöht die Korrektheit auf ca. 62 % unter geringer Einbuße der Vollständigkeit um in etwa fünf Prozentpunkte, wobei für Datensatz 3 die Steigerung der Korrektheit um 40 % am höchsten ist. Durch die Elimination vieler falscher Detektionen können im Hinblick auf die Erstellung einer Belastungskarte Bereiche entstehen, die als nicht durch Kriegseinwirkung gefährdet einzustufen sind (Abb. 8c, f, grüne Pfeile).

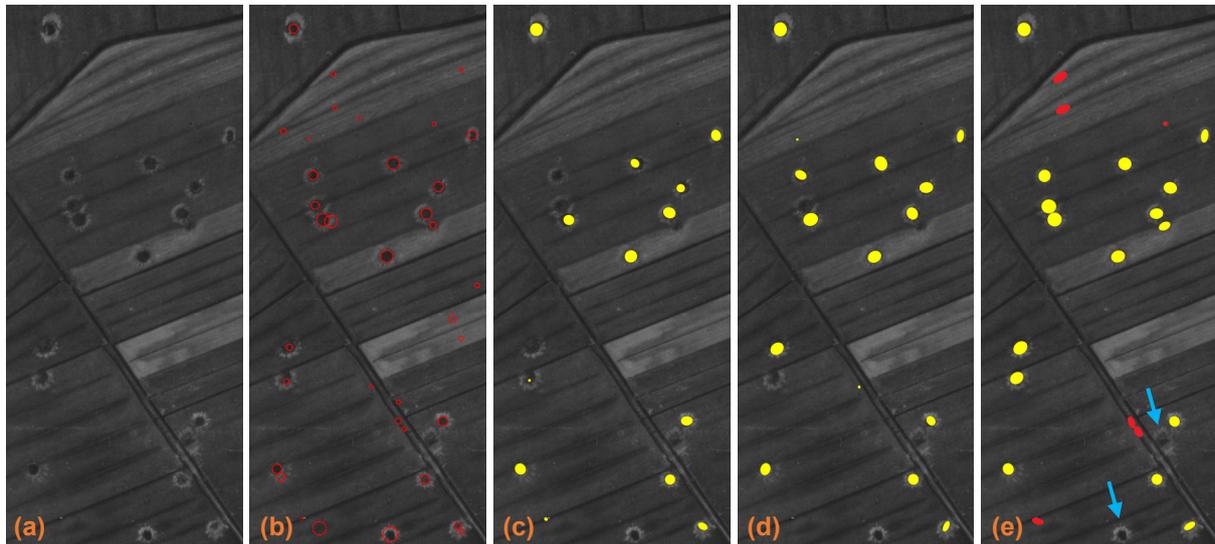


Abb. 7: (a) Datensatz 1 mit Bombenkratern, (b) Ergebnisse der Blob-Detektion (rote Kreise) und (c-e) die auf den Blob-Ergebnissen aufbauenden Resultate des Verfahrens der markierten Punktprozesse (Ellipsen) nach $1 \cdot 10^5$, $3 \cdot 10^5$ und $10 \cdot 10^5$ Iterationen, wobei korrekte Detektionen in Gelb und falsche Detektionen in Rot dargestellt sind.

Tab. 1: Zusammenstellung der Evaluierungsergebnisse

	Blob-Detektor		Markierte Punktprozesse	
	Vollständigkeit	Korrektheit	Vollständigkeit	Korrektheit
Datensatz 1	94,4%	47,2%	88,8%	72,7%
Datensatz 2	89,5%	38,6%	84,2%	55,2%
Datensatz 3	95,1%	16,9%	90,2%	56,9%
Mittelwert	93,0%	34,2%	87,7%	61,6%

Abschließend möchten wir kurz eine Schwäche unseres aktuellen Verfahrens aufzeigen. Objekte, die sich im Bild ähnlich wie Bombenkrater ausprägen, führen zu vielen Fehldetektionen. Hierfür sind insbesondere Schattenwürfe von Häusern (Abb. 9) oder auch Bäumen (Abb. 8d-f, rechts) verantwortlich. Im Ausblick (Abschn. 5) werden Ideen diskutiert, wie diesen Einschränkungen entgegengewirkt werden kann.

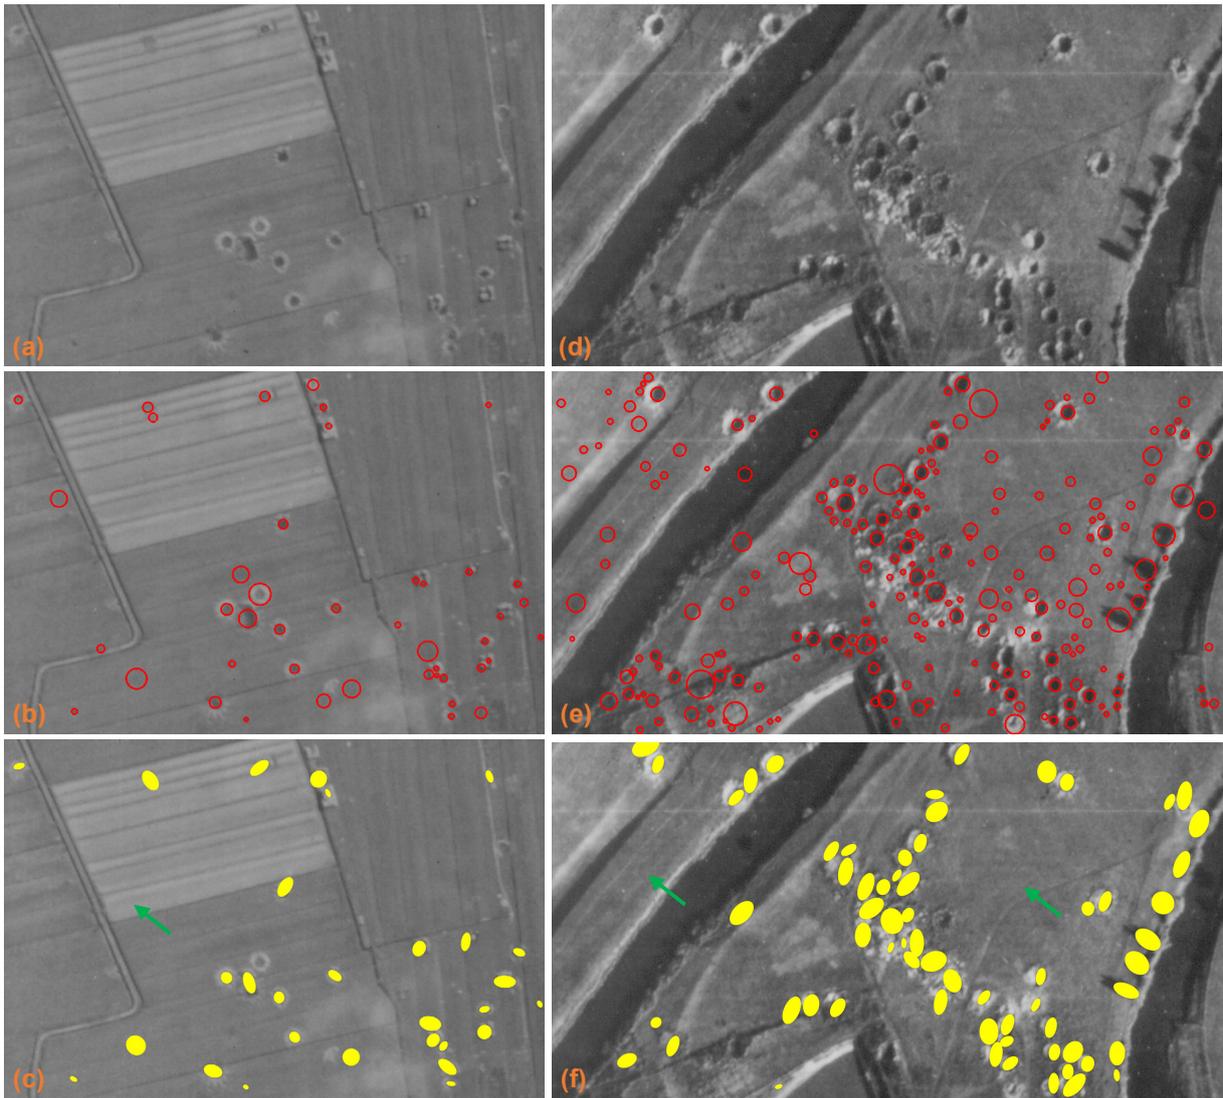


Abb. 8: (a, d) Datensätze 2 und 3 mit Bombenkratern, (b, e) Ergebnisse der Blob-Detektion (rote Kreise) und (c, f) die auf den Blob-Ergebnissen aufbauenden Resultate des Verfahrens der markierten Punktprozesse, wobei Ellipsen in Gelb dargestellt sind.

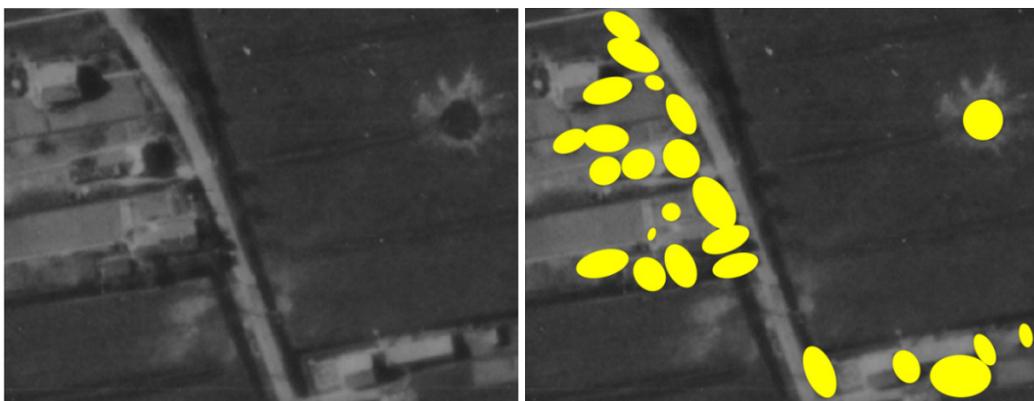


Abb. 9: Schattenbereiche (hier von Häusern verursacht) führen zu zahlreichen Fehldetektionen

5 Schlussfolgerungen und Ausblick

Wie die Ergebnisse zeigen, kann ein großer Teil der im Bild vorhandenen Bombenkrater durch den vorgestellten Ansatz gefunden werden, jedoch treten auch – abhängig vom Bildinhalt – Fehldetektion auf. Diese Ergebnisse zeigen das Potential, aber auch die derzeitigen Grenzen der Methode auf. Probleme entstehen vor allem durch Objekte, die sich im Bild ähnlich wie Bombenkrater ausprägen (z.B. Schatten von Häusern oder Bäumen). Um dem entgegenzuwirken, soll in Zukunft der Datenterm des Modells dahingehend erweitert werden, dass es auch einen Kranz an helleren Pixeln um den Ellipsenrand herum fordert (z.B. DESCAMPS et al. 2011). Dieses Phänomen ist in den Bildern aufgrund des bei der Detonation verursachten Auswurfs zu beobachten. In Gebieten mit stereoskopischer Abdeckung durch Bilder kann auch Höheninformation integriert werden, wobei die Qualität der Luftbilder einen limitierenden Faktor darstellen könnte. Ferner soll der Sonnenstand ebenso berücksichtigt werden wie der Umstand, dass Bombenkrater selten einzeln vorkommen. Daher sollte die Erweiterung des Priorterms um ein Modell für Kratergruppen die Ergebnisse weiter verbessern.

6 Danksagung

Die Autoren danken dem Landesamt für Geoinformation und Landesvermessung Niedersachsen (LGLN) und dem als Dezernat in die Regionaldirektion Hameln-Hannover des LGLN integrierten Kampfmittelbeseitigungsdienstes (KBD) herzlich für die Bereitstellung der Daten und die finanzielle Unterstützung des Projekts.

7 Literaturverzeichnis

- ANDRIEU, C., DE FREITAS, N., DOUCET, A. & JORDAN, M. I., 2003: An Introduction to MCMC for Machine Learning. *Machine Learning* **50**, 5-43.
- BORCS, A. & BENEDEK, C., 2015: Extraction of Vehicle Groups in Airborne Lidar Point Clouds With Two-Level Point Processes. *IEEE Transactions on Geoscience and Remote Sensing (GRS)* **53**(3), 1475-1489.
- BRÉDIF, M., TOURNAIRE, O., VALLET, B. & CHAMPION, N., 2013: Extracting polygonal building footprints from digital surface models: A fully-automatic global optimization framework. *ISPRS Journal of Photogrammetry and Remote Sensing* **77**, 57-65.
- CHAI, D., FÖRSTNER, W. & YING YANG, M., 2012: Combine Markov random fields and marked point processes to extract building from remotely sensed images. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* **I-3**, 365-370.
- DALEY, D. J. & VERE-JONES, D., 2003: An Introduction to the Theory of Point Processes: Volume I: Elementary Theory and Methods (2. Aufl.). *Probability and its Applications*. New York: Springer.
- DESCAMPS, S., DESCOMBES, X., BECHET, A. & ZERUBIA, J., 2008: Automatic Flamingo detection using a multiple birth and death process. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 1113-1116.

- DESCAMPS, S., BÉCHET, A., DESCOMBES, X., ARNAUD, A. & ZERUBIA, J., 2011: An automatic counter for aerial images of aggregations of large birds. *Bird Study* **58**(3), 302-308.
- DESCOMBES, X. & ZERUBIA, J., 2002: Marked Point Process in Image Analysis. *IEEE Signal Processing Magazine* **19**(5), 77-84.
- DESCOMBES, X., 2013: Marked Point Processes for Object Detection. *Stochastic Geometry for Image Analysis*, Descombes, X. (Hrsg.), John Wiley & Sons, Inc., Hoboken: Wiley, 11-27.
- DUBOSCLARD, P., LARNIER, S., KONIK, H., HERBULOT, A. & DEVY, M., 2014: Automatic Method for Visual Grading of Seed Food Products. *International Conference on Image Analysis and Recognition (ICIAR)* **1**, 485-495.
- GEMAN, S. & GEMAN, D., 1984: Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)* **6**(6), 721-741.
- GILKS, W. R., RICHARDSON, S. & SPIEGELHALTER, D., 1996: *Markov Chain Monte Carlo in Practice*. Chapman & Hall/CRC Interdisciplinary Statistics: Taylor & Francis.
- GREEN, P. J., 1995: Reversible jump Markov chain Monte Carlo computation and Bayesian model determination. *Biometrika* **82**(4), 711-732.
- HASTINGS, W. K., 1970: Monte Carlo sampling methods using Markov chains and their applications. *Biometrika* **57**(1), 97-109.
- KIRKPATRICK, S., GELATT, C. D. & VECCHI, M. P., 1983: Optimization by Simulated Annealing. *Science* **220**(4598), 671-680.
- KUMAR, S. & HEBERT, M., 2006: Discriminative Random Fields. *International Journal of Computer Vision* **68**(2), 179-201.
- LACOSTE, C., DESCOMBES, X. & ZERUBIA, J., 2005: Point processes for unsupervised line network extraction in remote sensing. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)* **27** (10), 1568-1579.
- LAFARGE, F., GIMEL'FARB, G. & DESCOMBES, X., 2010: Geometric feature extraction by a multimarked point process. *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)* **32**(9), 1597-1609.
- LI, S. Z., 2009: *Markov Random Field Modeling in Image Analysis* (3. Aufl.). London: Springer.
- MALLET, C., LAFARGE, F., ROUX, M., SOERGEL, U., BRETAR, F. & HEIPKE, C., 2010: A Marked Point Process for Modeling Lidar Waveforms. *IEEE Transactions on Image Processing (IP)* **19**(12), 3204-3221.
- MALLICK, S., 2015: Blob Detection Using OpenCV (Python, C++).
<https://www.learnopencv.com/blob-detection-using-opencv-python-c/>, letzter Zugriff Dezember 2016.
- METROPOLIS, N., ROSENBLUTH, A. W., ROSENBLUTH, M. N., TELLER, A. H. & TELLER, E., 1953: Equation of State Calculations by Fast Computing Machines. *The Journal of Chemical Physics* **21**(6), 1087-1092.
- PERRIN, G., DESCOMBES, X. & ZERUBIA, J., 2005: Adaptive Simulated Annealing for Energy Minimization Problem in a Marked Point Process Application. *Energy Minimization Methods in Computer Vision and Pattern Recognition*, RANGARAJAN, A., VEMURI, B. & YUILLE, A. (Hrsg.), Berlin Heidelberg: Springer, 3-17.

- PERRIN, G., DESCOMBES, X. & ZERUBIA, J., 2006: 2D and 3D Vegetation Resource Parameters Assessment using Marked Point Processes. International Conference on Pattern Recognition (ICPR), 1-4.
- SALAMON, P., SIBANI, P. & FROST, R., 2002: Facts, Conjectures, and Improvements for Simulated Annealing. Society for Industrial and Applied Mathematics. Philadelphia, USA.
- SCHMIDT, A., KRUSE, C., ROTTENSTEINER, F., SOERGEL, U. & HEIPKE, C., 2016: Network detection in raster data using marked point processes. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences **XLI-B3**, 701-708.
- SUN, K., SANG, N., & ZHANG, T., 2007: Marked Point Process for Vascular Tree Extraction on Angiogram. Energy Minimization Methods in Computer Vision and Pattern Recognition, YUILLE, A., ZHU, S.-C., CREMERS, D. & WANG, Y. (Hrsg.), Berlin Heidelberg: Springer, 467-478.
- TOURNAIRE, O., BRÉDIF, M., BOLDO, D. & DURUPT, M., 2010: An efficient stochastic approach for building footprint extraction from digital elevation models. ISPRS Journal of Photogrammetry and Remote Sensing **65**(4), 317-327.
- TROGLIO, G., BENEDIKTSSON, J., MOSER, G. & SERPICO, S., 2010: Crater detection based on marked point processes. Proceedings of the International Geoscience and Remote Sensing Symposium, Honolulu, 1378-1381.
- UTASI, A. & BENEDEK, C., 2011: A 3-D marked point process model for multi-view people detection. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 3385-3392.
- VAN LAARHOVEN, P. J. & AARTS, E. H., 1987: Simulated Annealing: Theory and Applications. Ellis Horwood Series in Mathematics and Its Applications. Niederlande: Springer.
- WENZEL, S. & FÖRSTNER, W., 2016: Facade interpretation using a marked point process. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences **III-3**, 363-370.
- ZHANG, J., SOHN, G. & BRÉDIF, M., 2014: A hybrid framework for single tree detection from airborne laser scanning data: A case study in temperate mature coniferous forests in Ontario, Canada. ISPRS Journal of Photogrammetry and Remote Sensing **98**, 44-57.