

Visualisierung von Veränderungen in Katastrophengebieten mittels texturbasierter Auswerteverfahren

Daniel Tomowski¹, Sascha Klonus¹, Manfred Ehlers¹, Ulrich Michel², Peter Reinartz³

¹*Institut für Geoinformatik und Fernerkundung, Universität Osnabrück, dtomowski, sklonus, mehlers@igf.uni-osnabrueck.de*

²*Pädagogische Hochschule Heidelberg, michel@ph-heidelberg.de*

³*Deutsches Zentrum für Luft- und Raumfahrt, peter.reinartz@dlr.de*

Abstract. Die schnelle Erfassung und Visualisierung von Veränderungen in Krisengebieten stellt eine entscheidende Voraussetzung für die Planung und Koordination von Hilfsmaßnahmen dar [1]. Durch die Etablierung neuer Satelliten mit hohen zeitlichen und räumlichen Auflösungsvermögen (z. B. Quickbird) stehen neue Datenquellen bereit, die eine verbesserte Visualisierung von räumlichen Veränderungen ermöglichen. In der Vergangenheit wurde eine Vielzahl von Methoden zur Analyse von Veränderungen entwickelt und getestet. Dieser Artikel beschreibt Ansätze, Texturmerkmale [2] mit Methoden der Veränderungsanalyse zu verknüpfen, um Veränderungen von Siedlungsflächen automatisiert ohne Schwellwertbestimmung zu visualisieren. Bei einem Vergleich unterschiedlicher Texturmerkmale wurden die besten Ergebnisse mit dem Texturmerkmal „Energy“ und dem Einsatz einer texturbasierten bitemporalen selektiven Hauptkomponentenanalyse erzielt.

Keywords. Veränderungsanalyse, Textur, Katastrophengebiete, hochauflösende Satellitenbilddaten

Einleitung

Seit der Etablierung der Satellitenfernerkundung wurde eine Vielzahl von Methoden von Veränderungsanalysen für eine Vielzahl von Anwendungsbereichen entwickelt und getestet. Vergleichende Überblicke existieren z. B. bei [3], [4] oder [5]. Zusammenfassend lässt sich feststellen, dass in der Wissenschaft keine einheitliche Meinung herrscht, welche Methode am besten oder genauesten ist. Eine große Bandbreite von unterschiedlichen Methoden, die nach [6] einen unterschiedlichen Grad an Flexibilität, Robustheit, Anwendbarkeit und Aussagekraft aufweisen, werden nach [4] in der Regel drei Kategorien zugeordnet:

- (1) Image-Enhancement-Verfahren (Verfahren zur Bildverbesserung),
- (2) multitemporale Bildanalyse (gemeinsame Analyse von zwei Bildern) und
- (3) Postklassifikationsbildanalyse (unabhängiger Klassifikationsvergleich).

Da das Themenfeld fernerkundlicher Veränderungsanalysen ein hochaktuelles Forschungsthema ist existieren eine Vielzahl von weiteren Methoden und Anwendungen, die an dieser Stelle nicht aufgeführt werden können. Weitere Ansätze kombinieren z. B. existierende Verfahren miteinander oder verfolgen komplett anders-

bzw. neuartige Methoden. Hierzu gehören z. B. künstliche neuronale Netzwerke [7], die Fuzzy-Theorie [8] oder objektorientierte Ansätze [9]. Eine Übersicht ist z. B. bei [5] zu finden.

2. Theoretischer Hintergrund

Dieser Abschnitt stellt zuerst die verwendeten Methoden zur Veränderungsanalyse vor und geht im zweiten Teil auf die Berechnung der Texturmerkmalsbilder ein.

2.1 Methoden für Veränderungsanalysen

Die verwendeten Methoden „Image-Differencing“ und „Image-Ratio“ sind einfach zu implementieren und wurden vielfach diskutiert und publiziert [10] [3] und werden daher nicht näher erläutert.

Regressionsanalysen ermitteln die Art und den Grad des Zusammenhanges zwischen Merkmalen, d. h. dieser Ansatz geht von der Annahme aus, dass zwischen den Grauwertpixeln einer identischen Fläche zu zwei Zeitpunkten eine Beziehung besteht oder nicht besteht. Die Beziehung wird in unserer Arbeit über eine Regressionsfunktion, die über die Methode der kleinsten Fehlerquadrate [11] ermittelt und wie in [5] analysiert.

Die Hauptkomponentenanalyse (PCA) dient der Berechnung neuer synthetischer Datensätze und einer Verstärkung von wellenlängenabhängigen und materialspezifischen Unterschieden. Für umfassende Darstellungen sei z. B. auf [12] verwiesen. Im Bereich der Veränderungsanalyse wird die PCA in unterschiedlichsten methodischen Variationen verwendet [13], in dieser Arbeit wird eine selektive PCA verwendet, die nachfolgend erläutert wird: Wird ein zweidimensionaler Merkmalsraum für bitemporale Spektralbänder für jeden spektralen Kanal gebildet (vgl. Abbildung 1), wird jedes Grauwertpixel eindeutig in Relation zu den Merkmalsvektoren bzw. Hauptkomponenten verortet. Die Grauwertpixel, die sich nicht verändert haben, weisen dabei eine starke Korrelation mit der ersten Hauptkomponente auf, die „Change Pixel“ jedoch nicht, da nach [10] die erste untersuchte Komponente die unveränderten Informationen, alle weiteren später für die Analyse genutzten Komponenten die veränderten Information beinhalten.




Abbildung 1. Visualisierung von Veränderungen über eine bitemporale PCA.

2.2 Berechnung der Texturmerkmalsbilder

Die Texturmerkmalsbilder wurden mittels sogenannter GLC-Matrizen, auch als Statistiken zweiter Ordnung bekannt [14], berechnet. Grundidee ist, dass Siedlungsflächen durch kleinteilige Bauweisen eine höhere Grauwertübergangswahrscheinlichkeit bzw. Textur aufweisen als andere Flächen. Zahlreiche Veröffentlichungen [15] [16] zur Analyse von Siedlungsflächen belegen dies.

GLCM dienen nach [17] dazu, die Wahrscheinlichkeit eines Übergangs vom Grauwertniveau i auf das Grauwertniveau j zweier benachbarter Bildelemente zu beschreiben, wodurch die spektrale als auch räumliche Verteilung von Grauwertpixeln analysiert wird. Konkret werden auf Grundlage der maximal möglichen Grauwertkombinationen die Häufigkeiten zweier benachbarter Grauwerte i und j mit fest definiertem Abstand für beide Nachbarn einer bestimmten Richtungsgraden vor- und rückwärts gezählt. Das Ergebnis ist eine symmetrische Matrix. Dieser Vorgang kann für alle vier möglichen Richtungen (horizontal, vertikal, linksdiagonal und rechtsdiagonal) berechnet werden. Werden die Mittelwerte der Matrizen je Matricelement berechnet, wird von einer richtungsunabhängigen GLC-Matrix gesprochen. Um nun die Wahrscheinlichkeit eines Grauwertübergangs auszudrücken, muss jeder Wert in einer GLCM durch die maximale Anzahl tatsächlich möglicher Grauwertübergänge dividiert werden. Dabei stehen i, j für die Zeilen- und Spaltennummer, V = Wert in einer symmetrischen GLC-Matrix und N für die Anzahl der Zeilen oder Spalten:

$$P_{i,j} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}} \quad (1)$$

Da die Erstellung einer GLCM bei hohen radiometrischen Auflösungen sehr rechen- und speicherplatzintensiv ist, verwenden [2] mehrere Texturmerkmale, die die Charakteristik der Matrix durch einen einzigen Wert ausdrücken. Dies geschieht über eine Fenstertechnik, die z.B. in [18] erläutert wird. Folgende Merkmale wurden in dieser Arbeit genutzt (vgl. Tabelle 1). Die Grauwerte werden durch i und j , die Auftretswahrscheinlichkeit als $p(i,j)$ und σ als Standardabweichung ausgedrückt:

Tabelle 1. Übersicht über die verwendeten Texturmerkmale.

Contrast	Correlation	Homogeneity	Energy
$\sum_{i,j} i-j p(i,j)$	$\sum_{i,j} \frac{(i-j)(i-j) p(i,j)}{\sigma^2}$	$\sum_{i,j} \frac{p(i,j)}{1+ i-j }$	$\sum_{i,j} p(i,j)^2$

$$\mu = \sum_{i,j} i p(i,j)$$

Mit

4. Konzeption und Umsetzung

Die verwendeten Aufnahmen eines Dorfes in Darfur (Shangil) stammen vom Satelliten Quickbird und zeigen das Untersuchungsgebiet am 10.3.2003 (links) und am 18.12.2006 (rechts) und wurden von Amnesty International bereitgestellt. Shangil wurde 2005 und 2006 mehrmals angegriffen bzw. zu 75 % zerstört (mehr Informationen hierzu auch unter: <http://shr.aaas.org/geotech/darfur/darfur.shtml>).




Abbildung 2. Untersuchungsgebiet vor (t_1) und nach (t_2) der Zerstörung.

Für die Analysen wurden künstlich erzeugte panchromatische Daten durch Mittelwertbildung der RGB-Daten generiert, da die originalen panchromatischen Daten zur Ermittlung der Texturwerte nicht vorlagen.

Die weiteren Verfahrensschritte vor der Durchführung der Veränderungsanalysen stellt Abbildung 3 dar. Generell werden die panchromatischen Bilddaten zuerst einer Histogrammanpassung unterzogen, dann die GLCM je Zeitpunkt berechnet um dann hieraus über die haralickschen Texturmerkmale die Texturmerkmalsbilder (je Zeitpunkt) zu berechnen. Erst im Anschluss werden die eigentlichen Veränderungsanalysen (Image-Differencing, Image-Ratio, Regression und PCA) mit den bitemporalen Texturmerkmalsbildern durchgeführt (vgl. Abbildung 3).

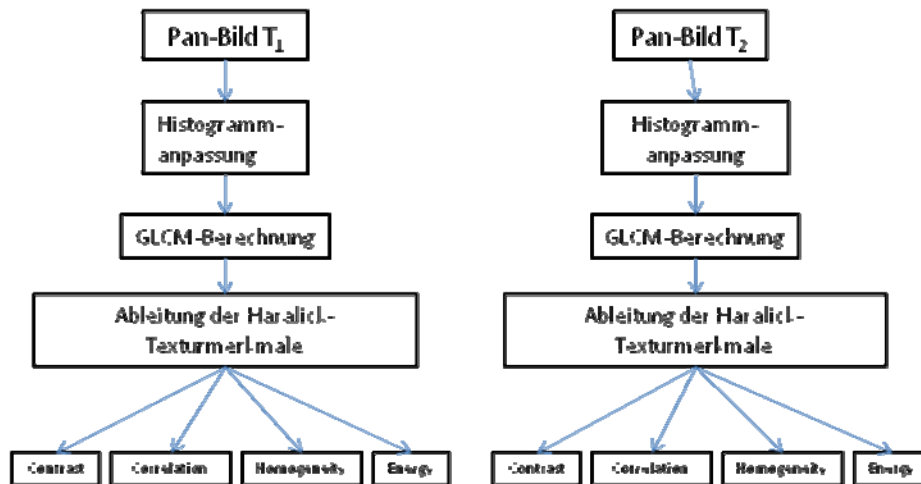


Abbildung 3. Verfahrensschema zur Ableitung der Texturbilder für die Veränderungsanalyse.

Grundlage für die Berechnung der Texturmerkmalsbilder bilden panchromatische Bilddaten aus den Zeitpunkten t_1 und t_2 . Aus jeder GLCM (8 bit) wurden unter der Verwendung von $3*3$, $7*7$ und $13*13$ Fenstern die Texturmerkmale „Contrast“, „Correlation“, „Homogeneity“ und „Energy“ ohne eine Histogrammanpassung berechnet, um den Effekt von unterschiedlichen Beleuchtungsverhältnissen zu testen. Hierbei zeigte sich schnell, dass durch unterschiedliche Beleuchtungsverhältnisse zu den beiden Zeitpunkten die Veränderungsanalyse zu ungenauen Ergebnissen führt, da die Wertebereiche der Grauwerte nicht vergleichbar sind. Um mögliche Pseudo-Change-Effekte zu verhindern, wurden die Histogramme der Eingangsdatensätze in weiteren Testreihen vorher aufeinander angepasst. Es zeigte sich nach manueller Bildinterpretation, dass durch diese Anpassung die Texturen bzw. Siedlungsstrukturen, die über $3*3$, $7*7$ Fenster generiert wurden, schlechter erkennbar waren, als zuvor. Einzig die aus $13*13$ Fenstern berechneten Texturmerkmalsbilder konnten die gesuchten Siedlungsstrukturen am besten hervorheben, so dass diese Fenstergröße für die folgenden Testreihen verwendet wurde. Nach Abschluss dieser Vorverarbeitungsschritte wurden die eigentlichen Veränderungsanalysen durchgeführt, deren Resultate im folgenden Abschnitt vorgestellt werden.

5. Ergebnisse und Zusammenfassung

Da die Vorstellung aller Ergebnisse (es wurden insgesamt 16 Ergebnisbilder generiert) den Umfang dieses Artikels übersteigt, werden an dieser Stelle nicht alle Resultate, sondern nur das beste Ergebnis vorgestellt.

Tabelle 2 fasst jedoch zuvor die weiteren Ergebnisse mittels einer bewertenden Gegenüberstellung, die auf einer visuellen Interpretation beruht von Texturmerkmalen (horizontal) und Analyseverfahren (vertikal) zusammenfassend dar:

Tabelle 2. Bewertung der Visualisierungen aus den Veränderungsanalysen.

Methoden\Merkmal	Contrast	Correlation	Homogeneity	Energy
Image-Differencing:	-	-	-	-
Image-Ratio:	-	-	0	0
Regression:	0	0	0	0
PCA:	-	-	-	+

Bewertung: „+“ = gut ; „0“ = mittel; „-“ = unbefriedigend

Zusammenfassend führte das Image-Differencing-Verfahren bei allen vier getesteten Texturmerkmalen zu unbefriedigenden Ergebnissen. Zusätzlich müssten in weiteren Auswerteschritten Schwellwerte hergeleitet werden, so dass der Zeitaufwand bei diesem Verfahren als hoch einzuschätzen ist. Weitere Untersuchungen zum Einsatz von texturbasierten Image-Differencing-Verfahren sind daher aus unserer Sicht nicht erfolgversprechend. Das texturbasierte Ratio-Verfahren liefert für die Merkmale „Contrast“ und „Correlation“ keine befriedigende Resultate; mittels des Homogeneity- und Energymerkmals lassen sich jedoch in Teilen Veränderungen an Siedlungsflächen visuell feststellen. Die texturbasierte Regressionsanalyse liefert bei allen vier untersuchten Texturmerkmalen in Teilen brauchbare Informationen zu Veränderungen; Problem ist jedoch die ungenaue Eingrenzung von Umrissen bzw. Gebäudestrukturen. Gegebenenfalls wären diese Informationen in objektorientierten Auswerteverfahren nutzbar, um anhand vorhandener Objektgrenzen zu determinieren, ob sich die Textur in den untersuchten Objekten verändert hat.




Abbildung 4. Ergebnis der texturbasierten bitemporalen PCA mit dem Merkmal „Energy“.

Die texturbasierte bitemporale Hauptkomponentenanalyse liefert für die Merkmale „Contrast“, „Correlation“ und „Homogeneity“ unbefriedigende visuelle Ergebnisse. Vielversprechende Ergebnisse liefern dagegen das Merkmal „Energy“, da hier sowohl veränderte als auch unveränderte Siedlungsflächen in Ihrer Struktur sofort gut visualisiert werden können, ohne Schwellwerte ableiten zu müssen (siehe Abbildung 4). Im Ergebnis sind die unveränderten Siedlungsflächen weiß und die veränderten Siedlungsflächen dunkelgrau dargestellt (das Umland wird in hellerem grau dargestellt).

Weitere zukünftige Arbeitsschritte werden die Anwendung der vorgestellten Methodik auf andere Satellitenbilddaten und weitere Katastrophenszenarien sein, insbesondere auch, um die Übertragbarkeit auf andere Klassenkombinationen außerhalb von ariden Regionen zu testen, wie z. B. Überflutungen, Erdbeben und anderen Naturkatastrophen.

6. Danksagung

Die Arbeiten wurden im Rahmen des Projektes „Automatisiertes Change Detection für Krisenanwendungen“ am Institut für Geoinformatik und Fernerkundung (IGF) der Universität Osnabrück durchgeführt und vom Deutschen Zentrum für Luft- und Raumfahrt e.V. (DLR) finanziert.

7. Literaturangaben

- [1] Künzel, W., in *Kartographie - Ihnen werden wir's zeigen*, edited by E. Theile (Kirschbaum, Bonn, 2007).
- [2] Haralick, R. M., Shanmugam, K. & Dinstein, I., Textural features for image classification, *IEEE Trans. Syst., Man, Cybern.* **SMC-3** (1973), 610–621.
- [3] Singh, A., Digital change detection techniques using remote-sensed data, *International journal of remote sensing* **10** (1989), 989–1003.
- [4] Mas, J. F., Monitoring land-cover changes: a comparison of change detection techniques, *International journal of remote sensing* **1** (1999), 139–152.
- [5] Lu, D., Mausel, P., Brondizio, E. & Moran, E., Change detection techniques, *International journal of remote sensing* **12** (2003), 2365–2407.
- [6] Niemeyer, I. & Nussbaum, S., in *Tagungsband des 7. Geokinematischen Tages vom 11. und 12. Mai 2006 in Freiberg*, edited by I. Niemeyer, A. Sroka & R. Wittenburg (Glückauf, Essen, 2006), 248–257.
- [7] Nemmour, H. & Chibani, Y., Fuzzy neural network architecture for change detection in remotely sensed imagery, *International journal of remote sensing* **3-4** (2006), 705–717.
- [8] Foody, G. M., Monitoring the Magnitude of Land-Cover Change around the Southern Limits of the Sahara, *Photogrammetric engineering & remote sensing* **7** (2001), 841–847.
- [9] Im, J., Jensen, J. R. & Tullis, J. A., Object-based change detection using correlation image analysis and image segmentation, *International journal of remote sensing* **1-2** (2008), 399–423.
- [10] Macleod, R. D. & Congalton, R. G., A Quantitative Comparison of Change-Detection Algorithms for Monitoring Eelgrass from Remotely Sensed Data, *Photogrammetric engineering & remote sensing* **3** (1998), 207–216.
- [11] Schwarze, J., *Grundlagen der Statistik I - Beschreibende Verfahren*, Verlag Neue Wirtschafts-Briefe, Herne/Berlin, 1998.
- [12] Schowengerdt, R. A., *Remote sensing. Models and methods for image processing*. Elsevier Academic Press, Amsterdam, 2007.
- [13] Nussbaum, S. & Menz, G., *Object-Based Image Analysis and Treaty Verification. New Approaches in Remote Sensing - Applied to Nuclear Facilities in Iran*, Springer Science+Business Media B.V., Dordrecht, 2008.

- [14] Sali, E. & Wolfson, H., Texture classification in aerial photographs and Satellite data, *International journal of remote sensing* **18** (1992), 3395–3408.
- [15] Myint, S. W., in *Urban Remote Sensing*, edited by Q. Weng & D. A. Quattrochi (CRC Press, Boca Raton, Fla., 2007), 109–136.
- [16] Steinnocher, K. T., in AGIT IX, 2.-4. Juli 1997, Salzburger Geographische Materialien, 143–152.
- [17] Tomowski, D., Ehlers, M., Michel, U. & Bohmann, G., *Objektorientierte Klassifikation von Siedlungsflächen durch multisensorale Fernerkundungsdaten (gi-reports@igf 3)*, Universität Osnabrück, 2006.
- [18] Lehmann, T., Oberschelp, W., Pelikan, E. & Repges, R., *Bildverarbeitung für die Medizin. Grundlagen, Modelle, Methoden, Anwendungen*, Springer, Berlin, 1997.