

---

# Mustererkennung beim geodätischen Monitoring im Rahmen eines Frühwarnsystems

Boris Resnik

Beuth Hochschule für Technik, Berlin · resnik@beuth-hochschule.de

## Zusammenfassung

Während geodätische und geotechnische Überwachungsmessungen inzwischen einen sehr hohen Automatisierungsgrad aufweisen, bleibt die Interpretation der Ergebnisse weitgehend dem Experten überlassen. Soll auch dieser Schritt einen gewissen Automatisierungsgrad erreichen, z.B. aufgrund der Notwendigkeit die Situation praktisch in Echtzeit zu analysieren, ist es erforderlich, das Expertenwissen zu systematisieren und in ein computergesteuertes Beurteilungssystem umzuwandeln. Dies stellt prinzipiell eine typische Aufgabe der Mustererkennung dar. Die computergestützten Auswertestrategien dieser Art sind inzwischen in vielen Anwendungsgebieten von der Gesicht- bis zur Spracherkennung zu finden. Für eine Anwendung im Rahmen eines Überwachungssystems ist jedoch eine fachbezogene Anpassung erforderlich. Für das Lösen solcher Aufgaben wurden vom Autor in den letzten Jahren unterschiedliche mathematische Algorithmen in einer Software umgesetzt und getestet.


## 1 Mustererkennung bei der Deformationsanalyse

In den letzten Jahren wurde mehrfach nachgewiesen, dass ein kontinuierliches und voll automatisches Monitoring mithilfe geodätischer und geotechnischer Sensoren sehr gut geeignet ist, um Anhaltspunkte in Bezug auf die Funktionsfähigkeit von Ingenieurbauwerken durch eine zeitnahe Analyse von vielfältigen Sensordaten zu erhalten. Die üblichen kommerziellen Softwarepakete für ein Monitoring dieser Art bieten neben dem Ansteuern von Sensoren und der Datensammlung bzw. -aufbereitung meistens auch eine Visualisierungskomponente, mit der die erfassten Zeitreihen in Echtzeit dargestellt werden können. Eine umfassende visuelle Analyse von Messdaten eines typischen Monitorings, das mithilfe von mehreren Hunderten Sensoren durchgeführt wird, ist jedoch nicht mehr möglich, weil sie schon allein wegen der enormen Längen der gewonnenen Zeitreihen mit dem „gesunden Menschenverstand“ nicht mehr zu bewältigen ist. Außerdem hat der stetige technische Fortschritt dazu geführt, dass solche Überwachungsaufgaben heute oftmals als ein Regelkreis angesehen werden. Dabei müssen in Abhängigkeit von einer festgestellten Reaktion eines Messobjektes unmittelbar und automatisch bestimmte Aktionen (konkrete organisatorische bzw. bautechnische Maßnahmen) eingeleitet werden. Ohne einer automatischen Erkennung von komplexen Zusammenhängen in den Messdaten ist eine solche Vorgehensweise unmöglich. Dies stellt prinzipiell eine Mustererkennung dar, d.h. die Fähigkeit, in einer Menge von Daten bestimmte Regelmäßigkeiten oder Gesetzmäßigkeiten zu erkennen.

Typische Beispiele für eine Mustererkennung sind Gesichts-, Text- oder auch Spracherkennung usw., die inzwischen jedem Computeranwender gut bekannt sind. Folglich existieren bereits zahlreiche Algorithmen für eine computergesteuerte Realisierung von solchen Auf-

gaben, die jedoch für jede spezielle Anwendung eine fachbezogene Anpassung erfordern. Übliche Muster besitzen Eigenschaften (Farbwerte, Abmessungen, Strukturen usw.), die für ihre Zugehörigkeit zu einer Klasse charakteristisch sind. Zur Untersuchung eines interessierenden Sachverhaltes sind allerdings einige dieser Eigenschaften besonders wichtig und werden deswegen als „Merkmale“ bezeichnet. In diesem Beitrag wird diese klassische Vorgehensweise nicht ausführlich behandelt und stattdessen auf die entsprechende Fachliteratur (z.B. NIEMANN 2003 oder FLETTLING 2010) verwiesen.

Die Zielsetzung der Mustererkennung beim Detektieren von signifikanten Bauwerksdeformationen ist es grundsätzlich, die gewonnenen Messwerte einer bestimmten Klasse mit bestimmten charakteristischen Merkmalen zuzuordnen. Zu solchen Merkmalen gehören z.B. Mittelwert, Streuung, Neigung der angepassten Regressionsgerade usw. in einem vorgegebenen Abschnitt der Zeitreihe. In der Abbildung 1 ist diese Vorgehensweise exemplarisch am Beispiel von vier typischen Klassen dieser Art veranschaulicht. Zum besseren Verständnis der Zusammenhänge sind in dieser Abbildung auch die typischen Basismuster präsentiert, die zum Erkennen von markanten Objekten wie Gesichter in digitalen Bildern in Echtzeit verwendet werden. Dieses Verfahren der Mustererkennung wurde 2001 von Paul Viola und Michael Jones (VIOLA & JONES 2001) vorgeschlagen und erlangte inzwischen eine weltweite Popularität wegen seiner Effizienz. Genauso wie bei der Bildanalyse können auch bei den hier behandelten Aufgaben durch Verschieben eines entsprechenden Rechteckfensters die signifikanten Abweichungen vom „Normalverhalten“ aufgespürt werden, die dann ggf. in mehreren weiteren Stufen (Kaskaden) automatisch genauer untersucht werden können.



**Abb. 1:** Typische Muster beim Online-Monitoring (exemplarisch)

Da eine detaillierte Beschreibung von mathematischen Zusammenhängen den Umfang des Beitrages sprengen würde, kann in diesem Beitrag auf die Erkennungsalgorithmen bei allen vier o.g. Klassen (Abbildung 1) nur sehr kurz eingegangen werden. Die Algorithmen bei den Klassen „Sprung“ und „Trendänderung“ wurden vom Autor außerdem früher in den Beiträgen RESNIK & LUCHKO 2013 und RESNIK 2018 etwas ausführlicher erläutert. Die Vorgehensweise bei allen genannten Klassen weist eine große Ähnlichkeit auf. Dabei können grundsätzlich keine Einzelwerte sondern ausschließlich die Einzelfenster der vorgegebenen Größe miteinander verglichen werden. Der Ausdehnung von diesen Intervallen ist erfahrungsgemäß eine besondere Aufmerksamkeit zu schenken. Ein schmaleres Analysefenster erlaubt eine schlechtere Erfassung der gesuchten Parameter mit einem kleinen Freiheitsgrad, die jedoch wesentlich genauer zeitlich lokalisiert werden können. Es ist deswegen ratsam, zunächst die verdächtigen Ereignisse mit einem relativ großen Fenster aufzuspüren, um sie später mit immer kleineren Intervallen detaillierter zu untersuchen.

Die Klasse „Streuungsänderung“ besitzt nur ein relevantes Merkmal. Im Fall einer Normalverteilung handelt es sich dabei um die empirische Varianz  $s_i^2$ , deren Schätzung immer in einem Fenster (bzw. Intervall)  $i$  erfolgt. In der mathematischen Statistik wird ein signifikan-

ter Unterschied zwischen den Varianzen in zwei Fenstern mit dem F-Test (vgl. z.B. NIEMEIER 2008) festgestellt. Deswegen wird nach dem Erfassen eines neuen Wertes das Verhältnis von Varianzen  $F = s_1^2 / s_2^2$  z. B. aus dem aktuellen und vorletzten Intervall aus N Werten (ohne Überlappung) ermittelt. Folglich wird eine übliche Signifikanzanalyse im Vergleich zum Grenzwert  $F_{(\alpha/2)}$  mit der gewählten Irrtumswahrscheinlichkeit  $\alpha$  und mit den Freiheitsgraden  $f_1$  und  $f_2$  durchgeführt.

Bei der Untersuchung des Datenmaterials auf die eventuell vorhandenen Muster „Sprung“ kann bei jedem neuen Messwert ein Mittelwert  $y_m$  und seine empirische Standardabweichung  $s_m$  in einem Intervall aus den letzten N Werten berechnet werden, die hier als zwei unterschiedlichen Merkmale des Prozesses zu verstehen sind. Dann werden die Differenzen von ermittelten Mittelwerten  $d_m = |y_{m1} - y_{m2}|$  z. B. aus dem aktuellen und vorletzten Intervall (ebenfalls ohne Überlappung) und die entsprechende Standardabweichung der Differenz  $s_{dm}$  berechnet. Folglich wird eine übliche Signifikanzanalyse (Student-Verteilung) mit dem Testwert  $t = d_m / s_{dm}$  durchgeführt. Ein wesentlicher Unterschied des Musters „Impuls“ besteht darin, dass dabei die Differenz  $d_m = |y_i - y_m|$  des Einzelwertes  $y_i$  und des Mittelwertes  $y_m$  eines gemeinsamen Intervall zwischen  $(i - N/2)$  und  $(i + N/2)$  um diesen Wert  $i$  ermittelt wird.

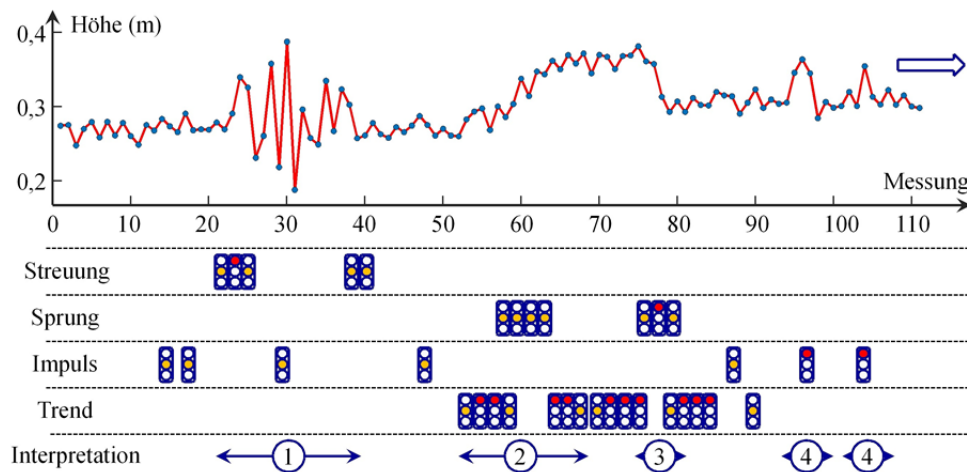
Die mathematische Lösung der Echtzeitauswertung für ein Muster „Trendänderung“ beinhaltet im Unterschied zu den beiden letztgenannten Klassen eine Anpassung einer Regressionsgerade  $y_t = b \cdot t + a$  in einem Intervall nach der Methode der kleinsten Quadrate. Die Berechnung der Steigung  $b$  und eine Abschätzung seiner empirischen Standardabweichung  $s_b$  muss nach dem Eingang jedes neuen Messwertes wiederholt werden. Danach werden die Differenzen von ermittelten Steigungen  $d_b = |b_1 - b_2|$  z. B. aus dem aktuellen und vorletzten Intervall aus N Werten (ohne Überlappung) und die entsprechende Standardabweichung der Differenz  $s_{db}$  sowie ein Testwert  $t = d_b / s_{db}$  berechnet.

Bei den Mustern „Sprung“, „Impuls“ und „Trend“ wird abschließend eine übliche Signifikanzanalyse im Vergleich zum Grenzwert  $t_{(\alpha/2)}$  mit der gewählten Irrtumswahrscheinlichkeit  $\alpha$  und mit den entsprechenden Freiheitsgraden  $f_1$  und  $f_2$  durchgeführt (vgl. z.B. NIEMEIER 2008). Bei der Analyse muss außerdem berücksichtigt werden, dass in Unterschied zum Muster „Impuls“ bei den drei anderen Typen eine signifikante Änderung mit der zeitlichen Verspätung um N-Werte festgestellt wird. Beim erstgenannten Muster beträgt diese Verspätung dagegen nur N/2-Werte.

## 2 Interpretation von Ergebnissen der Mustererkennung

In der Fachliteratur werden Mustererkennungsprozesse häufig mit Algorithmen in Verbindung gebracht, die selbständig Klassen aus den Messdaten gewinnen. D. h., es bedarf zunächst einer repräsentativen Stichprobe, um das System „anzulernen“. In diesem Beitrag wird dieser Anlernprozess jedoch vollkommen vernachlässigt, da die Klassen durch Expertenwissen bereits definiert wurden. Der vereinfachte Ablauf des behandelten Prozesses kann folglich in die Schritte „Datenerfassung“, „Extrahieren von Merkmalen“, „Klassifizieren von unterschiedlichen Mustern in mehreren Schritten“ und abschließend „Interpretation von Ergebnissen“ unterteilt werden.

Bei den realen Projekten können selbstverständlich auch die beliebigen Kombinationen aus den hier behandelten Klassen (Abbildung 1) entstehen, was ein sicheres Erkennen eines Musters zusätzlich erschweren könnte. Interpretationsprobleme können auch auftreten, wenn ein gleiches Merkmal bei den unterschiedlichen Klassen verwendet wird. So werden die Muster „Sprung“ und „Trendänderung“ oftmals auch mit dem Erkennen des Musters „Streuungsänderung“ begleitet, da solche systematische Änderungen in den Messdaten ohne Vorkenntnisse zunächst auch als eine höhere Variation um den Mittelwert (Streuung) interpretiert werden. Auch ein deutlich erkennbares Muster „Sprung“ kann bei den bestimmten Voraussetzungen von dem Algorithmus zusätzlich als eine „Trendänderung“ interpretiert werden, um hier exemplarisch nur zwei typische Beispiele dieser Art zu nennen. Um die ganz unterschiedlichen Szenarien der Echtzeitauswertung beim Monitoring unter Berücksichtigung von allen genannten Klassen der Deformationen zu testen, wurde im Rahmen eines Forschungsprojektes ein spezielles Programmsystem aus zwei Blöcken „Generator“ und „Detektor“ erstellt (vgl. RESNIK 2018). Mit dem erstgenannten Modul können unterschiedliche Datenänderungen nach bestimmten Voreinstellungen simuliert werden. Diese Daten werden dann im Echtzeitmodus von dem zweitgenannten Programm analysiert und bis zur Alarmierung ausgewertet. Statt der simulierten Daten können später im zweiten Modul auch die realen Messdaten aus einem üblichen Überwachungssystem verwendet werden.



**Abb. 2:** Typisches Beispiel der Datenauswertung beim Online-Monitoring

Diese Vorgehensweise wird im Beitrag anhand eines typischen Beispiels veranschaulicht. Die Abbildung 2 zeigt exemplarisch den Ablauf der Interpretation von typischen Messergebnissen einer vollautomatischen trigonometrischen Höhenmessung mit einem Tachymeter über mehr als hundert Einzelmessungen (etwa ein Mal pro Stunde) im Echtzeitmodus. In der ersten Stufe der Datenanalyse wurden zunächst die aktuelle Messwerte unabhängig auf vier unterschiedlichen Klassen untersucht, wobei in der Abbildung die mit rot (Oben, Irrtumswahrscheinlichkeit von 1%, beidseitig) und mit gelb (Mitte, Irrtumswahrscheinlichkeit von 5%, beidseitig) gezeichneten Ampeln die erkannten Muster präsentieren. Die in der Abbildung präsentierten Ergebnisse sind exemplarisch in den Intervallen von jeweils 9

Einzelwerten berechnet. Die Verschiebung des Zeitpunktes von festgestellten Ereignissen zum Anfang von den entsprechenden Fenstern ist bereits berücksichtigt. Diese Ergebnisse können jedes Mal in den weiteren Hierarchiestufen unter Berücksichtigung von allen festgestellten Mustern „verfeinert“ werden, wobei automatisch die folgende Interpretation des aktuellen Zustandes des Bauwerkes bzw. Messsystems ausgegeben wird:

- Intervall 1: Schwingungen (Erschütterungen) der Konstruktion bzw. wachsende zufällige Abweichungen bei den Messungen (z.B. Verschlechterung der Messgenauigkeit durch atmosphärisches Flimmern usw.),
- Intervall 2: Langsame Deformation des Bauwerkes in eine Richtung bzw. wachsende systematische Abweichungen bei den Messungen (z.B. durch eine langsame Änderung von atmosphärischen Bedingungen usw.),
- Intervall 3: Schnelle Deformation des Bauwerkes in eine Richtung bzw. grobe Fehler bei den Messungen (z.B. durch eine sprunghafte Änderung am Standpunkt usw.),
- Intervall 4: Grobe Messfehler ohne Änderung des Mittelwertes als Impuls.

Entscheidend für die zutreffende Beurteilung des Deformationsverhaltens von Bauwerken ist dabei offensichtlich die Trennbarkeit zwischen den tatsächlich stattgefundenen Deformationen und den Effekten, die durch die Mess- und Auswerteverfahren induziert werden. Diese Trennung ist nur mit einem Multisensorsystem erreichbar und wird hier deswegen nicht näher behandelt.

Eine Interpretation von vorliegenden Beobachtung im Rahmen der automatischen Datenauswertung ist am Ende immer mit dem Treffen von bestimmten Entscheidungen verbunden, die je nach der Situation erhebliche Kosten (sowohl bei einem falschen Alarm als auch bei den unbemerkten Erscheinungen) verursachen können. Eine optimale Software arbeitet so, dass die Kosten und das Risiko bei der Klassifikation minimiert werden. Die Entwicklung von solchen Produkten erfordert deswegen eine intensive interdisziplinäre Forschungsarbeit, wobei die Erfahrungen mit der Messtechnik und Zeitreihenanalyse mit dem Expertenwissen im Bereich des Bauwesens verknüpft wurden müssen.

## Literatur

- FLETTLING, R. (2010): Methodische Ansätze zur unscharfen Mustererkennung bei Deformationsmessergebnissen, TU Braunschweig. Geodätische Schriftenreihe Band Nr. 27.
- NIEMANN, H. (2003): Klassifikation von Mustern. 2. überarbeitete Auflage. <http://www5.cs.fau.de/fileadmin/Persons/NiemannHeinrich/klassifikation-von-mustern/m00links.html>
- NIEMEIER, W. (2008): Ausgleichsrechnung. 2. Auflage. 508 Seiten. Walter de Gruyter Verlag. Berlin.
- RESNIK B. (2018): Mustererkennung beim geodätischen Monitoring im Rahmen eines Frühwarnsystems. AVN Allgemeine Vermessungs-Nachrichten. Wichmann Verlag, Berlin / Offenbach, Heft 3, S. 63-69.
- RESNIK B. & LUCHKO Y. (2013): Verwendung schneller Wavelet-Transformation zum Detektieren von signifikanten Abweichungen im Rahmen eines Frühwarnsystems. In: Domnick & Heimann (Hrsg.), Forum GeoBau, Bd.4, Shaker Verlag, Aachen, S. 34 - 40.

VIOLA P. & JONES M. (2001): Robust Real-time Object Detection. International Journal of Computer Vision.