

Automatische Geologie-Klassifikation von TBM-Daten

Statistische Mustererkennung als Ansatz zur automatischen Klassifikation geologischer Eigenschaften in einem TBM-Sensordatenbestand

Von Gerhard Mitterlechner, Helmut A. Mayer und Gert Furtmüller

Der maschinelle Vortrieb mit Tunnelbohrmaschinen hat gegenüber dem traditionellen Sprengvortrieb wesentliche Vorteile, vor allem in Bezug auf die Vortriebsgeschwindigkeit. Aus dem Blickwinkel der geologischen Tunneldokumentation betrachtet ist ein Nachteil des Vortriebs mit Schildmaschinen, dass die Sicht zum Gestein verstellt ist, was eine verlässliche und lückenlose Tunneldokumentation erschwert. Der Vortrieb gleicht dadurch einem „Blindflug“ durch das Gebirge; maximal während der Wartungsschichten, also beim Stillstand der Maschine, ist über kleine Sichtfenster im Bohrkopf eine direkte Bestimmung der geologischen Verhältnisse möglich. Sicheres Wissen über geologische Parameter direkt am Bohrkopf würde wesentlich zur Optimierung der Vortriebsparameter (z. B. Maximierung der Vortriebs-

leistung, Minimierung von Verschleißerscheinungen), zur Ergänzung der geologischen Tunneldokumentation, aber auch zur Risikovermeidung in Zonen stark zerstörten Gesteins beitragen. Jedwede Schätzung oder Prognose der Gebirgsqualität an der Ortsbrust könnte also als wertvolle Entscheidungshilfe für den Maschinenfahrer oder zur Bestimmung erforderlicher bautechnischer Maßnahmen dienen.

Beim Vortrieb mit TBMs charakterisieren Sensoren den Zustand der Maschine in den verschiedenen Betriebsmodi (Vortrieb, Ringbau, etc.). Der Maschinenfahrer stützt seine Entscheidungen und Steuerungsaktionen im wesentlichen auf die Kombination gewisser Sensorwerte als Reaktion auf potentiell geänderte geologische Bedingungen, aber auch auf-

Automatic Classification of Geology Using TBM Data

For the optimization of TBM driving parameters, the complementation of the geological tunnel documentation, and the minimization of risk in zones of highly fractured rock, a computer-based system that is able to automatically make decisions on the type of geological conditions is desirable. We propose a classification system that correlates sensor data of the TBM with geological assessments in order to provide such an estimation.

The system relies on a machine learning method from statistical pattern recognition. By using Bayes' classification and techniques for the approximation of probability density functions, an estimation of the geological class-membership of a new TBM data set can be derived from the statistical model.

The system learns the structure of the data adaptively, and without a priori usage of domain- or expert knowledge, which makes it employable for a wide range of TBM tunnel projects. Recent experiments showed that a classification system based on this method is appropriate for practical application. Our approach is currently being realized as an additional software component of the tunnel documentation system 2doc by Pöyry Infra GmbH Salzburg.

Beim maschinellen Vortrieb wäre zur Optimierung von Vortriebsparametern, zur Ergänzung der Tunneldokumentation, sowie zur Risikovermeidung in Zonen stark zerstörten Gesteins ein computergestütztes System wünschenswert, das automatisiert Entscheidungen über die angetroffenen geologischen Eigenschaften treffen kann.

Wir stellen ein Klassifizierungssystem vor, mit der die Sensordaten der TBM mit geologischen Bewertungen korreliert werden, um in weiterer Folge bei Vorliegen neuer Sensordaten automatisiert eine Prognose der geologischen Verhältnisse abzugeben.

Das System benutzt ein Lernverfahren aus dem Bereich der statistischen Mustererkennung (*pattern recognition*). Mithilfe Bayes'scher Klassifizierung und Methoden zur Approximation von Wahrscheinlichkeitsdichtefunktionen kann bei Vorliegen eines neuen TBM-Datensatzes eine Schätzung der geologischen Klassenzugehörigkeit aus dem statistischen Modell abgeleitet werden.

Das System lernt adaptiv die Struktur der Daten, und ohne a priori Domänen- bzw. Expertenwissen einzubeziehen, wodurch es für beliebige TBM-Tunnelprojekte verwendbar ist. Experimente bestätigen die Einsetzbarkeit eines auf dieser Methode aufbauendes Klassifikationssystem in der Praxis. Softwaretechnisch wird unser Ansatz als zusätzliche Komponente des Tunneldokumentationssystems 2doc der Pöyry Infra GmbH Salzburg realisiert.

grund akustischer Veränderungen, dem Grad und der Art der Erschütterung der Maschine. Diese Tätigkeit ist analytisch schwer fassbar oder nachvollziehbar und verlangt große Erfahrung im Umgang mit der Maschine. Die Anzahl der verschiedenen Sensoren schwankt je nach Typ der TBM zwischen 100 und 550, und jede TBM weist spezifische Sensorkalibrierungen und Vortriebscharakteristika auf. Dies macht die Überwachung der Maschine mittels Sensoren, die korrekte Interpretation der gelieferten Werte, sowie die Beurteilung der geologischen Grundeigenschaften an der Ortsbrust schwierig, wenn nicht unmöglich. Diese Problematik drängt die Frage auf, inwieweit überhaupt relevante geologische Informationen aus den Sensordaten der TBM gewonnen werden können.

Im Folgenden stellen wir einen in der Informatik häufig eingesetzten und gut erforschten Problemlösungsansatz sowie die im Klassifizierungssystem verwendeten Verfahren vor und gehen kurz auf ähnliche Arbeiten ein. Experimentelle Ergebnisse rechtfertigen unseren Ansatz und die Wahl der eingesetzten Methoden. Danach beschreiben wir die Anforderungen an eine konkrete Implementierung als Softwarekomponente und ihre Funktionsweise.

[AutomatischeKlassifikationTBM-Daten.jpg]

Mustererkennung

Eine geeignete Herangehensweise an das Problem liefert das Gebiet der Mustererkennung (*pattern recognition*), indem das konkrete Problem als Klassifizierungsaufgabe formuliert wird. In unserem Fall wird versucht, die Information in den Sensordaten der TBM so auszunutzen, dass automatisiert Aussagen bezüglich der Kategorie geologischer Eigenschaften getroffen werden können.

Typische Anwendungen von Mustererkennungsmethoden sind automatische Buchstaben- und Schrifterkennung, Spracherkennung, automatische Klassifizierung von Satellitenbildern, Computer Vision, DNA Sequenzanalyse und Web Mining (1). Wir wenden erstmalig eng verwandte Methoden auf das Problem der Geologiebeurteilung aus TBM-Daten an.

Das zugrundeliegende Prinzip ist, abstrakt formuliert, für alle Anwendungen von Klassifizierungsalgorithmen dasselbe. Gegeben sind n d -dimensionale Datensätze (patterns), die als Punkte (Vektoren) im d -dimensionalen Raum aufgefasst werden. Jeder dieser Datenpunkte ist genau einer von c Klassen zugeordnet. Das Problem ist nun das Finden der Abbildung vom d -dimensionalen Raum in die Menge der Klassen, die für neue Datenpunkte mit noch unbekannter Klassenzugehörigkeit möglichst korrekt die entsprechende Klasse liefert. In der konkreten Anwendung auf TBM-Daten wird diejenige Abbildung gesucht, die für einen TBM-Sensordatensatz automatisch seine geologische Klassenzugehörigkeit bestimmt (Abb. 1).

Maschinelles Lernen

Die meisten Mustererkennungsmethoden benutzen überwachtes Lernen (*supervised learning*), um aus einer gewissen Datenmenge mit bekannter Klasseninformation (*Trainingsdaten*) die Struktur der Daten zu lernen, um danach die Daten gemäß ihrer Klasseneinteilung zu separieren. Im Unterschied zu *modellbasierten* Klassifikationsverfahren, wo der Mensch manuell ein analytisches Modell aufstellt, wird hier rein *beispielbasiert* gelernt (*learning by example*). Dies entspricht in etwa menschlichem Lernverhalten. In unserer Anwendung werden die Aussagen eines geologischen Experten (d. h. die durch ihn vorgenommene Einteilung des Gebirges in unterschiedliche Klassen) im Training mit den Sensordaten der TBM korreliert.

Abb. 1: Automatische Klassifikation der TBM-Sensordaten in geologische Klassen.

Fig. 1: Automatic classification of TBM sensor data into geological classes.

Zentrales Ziel eines jeden Lernalgorithmus ist eine hohe *Generalisierungsfähigkeit*, d. h., dass nach Abschluss des Trainings der trainierte Klassifizierer für neue Daten mit unbekannter Klasseninformation (*Testdaten*) die wahre Klasse erkennen kann. Vielfach eingesetzte Klassifizierungsalgorithmen basieren auf *Neuronalen Netzen*, *Entscheidungsbäumen*, *Support Vector Maschinen* (diskriminative Verfahren), oder statistischen Modellen (generative Verfahren) (2).

Statistische Mustererkennung

In der statistischen Mustererkennung wird versucht, die Wahrscheinlichkeit zu berechnen, mit der ein neuer Datenpunkt zu einer gewissen Klasse gehört (*posterior probability*). Über die *Bayes'sche Klassifizierungsformel* wird das Problem auf die Approximation der klassenspezifischen Wahrscheinlichkeitsdichtefunktionen (*class-conditional probability density functions*) reduziert, welche das eigentliche statistische Modell der Daten für jede einzelne Klasse darstellen. Zur Abschätzung dieser Dichtefunktionen (*density estimation*) verwenden wir nicht-parametrische Dichteschätzung mit Kernfunktionen (*Parzen Windows*) (1).

Der Vorteil statistischer Modellierung gegenüber diskriminativen Methoden liegt einerseits in einer soliden theoretisch-wissenschaftlichen Fundierung, andererseits in ihrer Einsetzbarkeit auch bei Vorliegen nur einer einzigen Klasse (Einklassenprobleme) bzw. stark unbalancierter Klassen, etwa zur Identifikation von Datenpunkten, die nicht dem bisher gelernten Modell entsprechen. So kann ein darauf aufbauendes Klassifizierungssystem auch Abweichungen von bisher gelernten Strukturen signalisieren, etwa beim Eindringen in einen neuen Gebirgsbereich.

Reduktion der Dimensionalität

Der „Fluch der Dimensionalität“ (*curse of dimensionality*) besagt, dass zur Beibehaltung einer gewissen Klassifizierungsleistung (Rate der korrekt klassifizierten Datenpunkte) die Anzahl der vorhandenen Trainingsdaten exponentiell in der Anzahl der Features, d. h. in der Anzahl der Komponenten pro Datenpunkt, wachsen muss (8). In unserem Fall entspricht jedem Feature genau ein Sensor (bzw. einer Sensorgruppe) der TBM. Da bei praktischen Problemen selten Trainingsdaten in ausreichender Menge vorhanden sind, ist eine Reduktion der Dimensionalität der Daten erforderlich, sodass möglichst relevante Information erhalten

bleibt, und redundante bzw. irrelevante Information verworfen wird. Feature Subset Selection Algorithmen finden diejenige (Teil)Menge von Features, mit denen die Klassifizierungsleistung am besten erscheint. Konkret benutzen wir eine greedy Methode, bei der, ausgehend von einer leeren Feature-Menge, iterativ immer dasjenige Feature zur Menge der bereits selektierten Features hinzugenommen wird, welches in Kombination die lokal beste Klassifizierungsleistung gibt (*forward selection*). Auf das konkrete Problem angewandt gibt Forward Selection automatisch eine Menge von Sensoren, die in Kombination am meisten Information zur Unterscheidung der geologischen Klassen beitragen (Abb. 2).

[FeatureSelection.jpg]

Abb. 2: Automatische Feature Selection von TBM-Sensoren.

Fig. 2: Automatic feature selection of TBM sensors.

Bisherige Arbeiten

Im Gegensatz zum Versuch die Vortriebsleistung der TBM mit den geologischen Bedingungen zu korrelieren (9) oder mithilfe Neuronaler Netze zu lernen (5), ist wenig bekannt über die automatische geologische Klassifizierung aus TBM-Sensordaten. In (10) wird eine Möglichkeit vorgestellt, mit einem Neuronalen Netz eine Prognose des Ausmaßes von Setzungen mithilfe TBM-Parameter zu bestimmen. Andere Ansätze gibt es mit seismischer Vorauserkundung (6) oder geostatistischen Methoden (7).

In (4) wird versucht, mit Fuzzy Logic aus den TBM-Parametern Vortriebsleistung; Stromaufnahme und Anpresskraft eine Schätzung für die Gebirgsklassen zu erhalten. Diesem Ansatz liegt kein Lernalgorithmus zugrunde, sondern eine Basis von Fuzzy Logic Regeln, welche manuell

für jedes Tunnelbauwerk neu erstellt werden müssen. Im Unterschied zu unserem universell anwendbaren, generischen Ansatz, wird also die Struktur der Daten nicht automatisch gelernt, sondern von einem menschlichen Experten zuerst analysiert, und dann in eine für den Computer brauchbare Form übersetzt (manuelle Regelextraktion). Das von uns vorgestellte Verfahren findet ausschließlich mithilfe der Klasseninformation in den Trainingsdaten (welche vom Geologen bereitgestellt wird) selbstständig relevante Features, wohingegen die Menge der TBM-Parameter beim Fuzzy-Logic Ansatz a priori vom Experten fixiert werden muss. Die in (4) propagierte Methode erlaubt es ebenso nicht, dass sich das Klassifizierungssystem automatisch an die geologischen Bedingungen adaptiert, wie dies beim hier vorgestellten System der Fall ist.

Ergebnisse

Zahlreiche Experimente und Analysen mit mehreren TBM-Datensätzen und geologischen Parametern haben folgende Erkenntnisse und Ergebnisse gebracht (3):

- Es besteht ein enger Zusammenhang zwischen den Sensordaten der TBM und den korrespondierenden geologischen Verhältnissen.
- Der Zusammenhang ist kompliziert. Regeln der Form „Wenn Anpresskraft $> x$ dann liegt Klasse y vor.“ sind für gute Klassifizierung ungenügend.
- Die konkrete Interaktion der Sensoren mit dem Gestein ist stark abhängig von der konkreten Maschine und dem jeweiligen Tunnelbauprojekt. Das Finden allgemeingültige Aussagen und Regeln ist in der Praxis kaum möglich.
- Vortriebsparameter wie Anpresskraft, Stromaufnahme und Drehmoment sind häufig tatsächlich relevant. Wesentliche Information ist aber auch in der Kombination zahlreicher anderer Parameter enthalten.
- Eine vorschnelle, a priori vorgenommene Selektion der TBM-Parameter kann zu starkem Verlust wertvoller Information führen. Das Verwenden aller Parameter hingegen führt zu großem Rauschen in den Daten. Eine (automatische) Selektion einer Teilmenge der TBM-Sensoren ist unumgänglich.
- Es ist mit Mustererkennungsmethoden möglich, automatisiert und ohne das Einbeziehen von Experten- oder Domänenwissen (mit Ausnahme der Be-

reitstellung der Klasseninformation in den Trainingsdaten durch den Geologen) geologische Information aus TBM-Daten zu gewinnen. Diese Methoden sind teilweise theoretisch anspruchsvoll, jedoch durchaus in der Praxis implementierbar.

- Konkret ist es uns bei einem Tunnelprojekt gelungen, Gestein schlechter Qualität von Gestein guter Qualität mit über 85% Klassifizierungsleistung (unter Verwendung von *nicht* zum Training verwendeten Testdaten!) zu unterscheiden. Bei einem anderen Projekt konnten wir mit einer durch automatische Feature Selection ermittelten Menge von zehn bis fünfzehn TBM-Sensoren fünf Gebirgsbereiche (Gebirgsklassen) mit jeweils über 95% Klassifizierungsleistung erkennen.
- Wesentlichen Einfluss auf die Güte des Klassifizierungsergebnisses haben die Trainingsdaten. Eine beispielsweise zu grobe oder zu detaillierte Klasseneinteilung, oder der Fokus auf für den TBM-Vortrieb irrelevante geologische Eigenschaften führen zu stark verschwimmenden Entscheidungsgrenzen, und die Klassifizierungsleistung sinkt. Wir betonen an dieser Stelle die enorme Bedeutung, die dem Geologen zukommt. Eine sorgfältige und kompetente Klasseneinteilung durch den geologischen Experten ist die absolute Grundvoraussetzung für brauchbare Trainingsdaten, und in weiterer Folge für akzeptable Klassifizierungsleistungen.

Das Klassifizierungssystem in der Praxis

Die Herausforderungen bei der praktischen Realisierung eines Systems zur automatischen Klassifizierung von geologischen Eigenschaften aus den Sensordaten einer Tunnelbohrmaschinen sind vielfältig. Eine zentrale Anforderung ist die Bedienbarkeit durch einen Anwender, der keinerlei Erfahrung mit den eingesetzten Methoden besitzt.

Eine weitere Anforderung ist die Anwendbarkeit für beliebige Tunnelprojekte. Das System kann und darf daher keinerlei TBM- oder tunnelprojektspezifischen Vorannahmen treffen. Dies führt dazu, dass der Klassifizierungsalgorithmus für jedes Projekt zu Beginn keinerlei Wissen über die Struktur der eintreffenden Daten hat, und schrittweise durch iterative Hinzunahme von Trainingsdaten die Zuordnung von Sensordaten zu den geologi-

schen Klassendaten *inkrementell* lernt und ständig adaptiert. Besonders erwähnenswert ist, dass auch die Auswahl der zu verwendenden TBM-Parameter im Laufe der Trainingsphasen vom System getroffen bzw. korrigiert wird.

Allgemeine Funktionsweise

Auf Basis von TBM-Daten wird eine computergestützte Zuordnung von während des Vortriebs angetroffenen geologischen Verhältnissen durchgeführt. Sämtliche Information über die Interaktion zwischen Fels und Maschine wird beispielbasiert nur anhand der TBM-Daten und den vom Experten vorgenommenen Klassenzuordnungen gelernt. Das Klassifikationssystem teilt nach einer anfänglichen Trainingsphase (die Länge der Trainingsphase ist abhängig von den geologischen Verhältnissen) die angetroffenen TBM-Parameter bereits gelernten Klassen oder der Klasse „unbekannt“ zu. Das System wird laufend an die neuen Verhältnisse angepasst (adaptives Lernen), der Geologe dient dabei als Trainer, der die Bewertungen des Systems überwacht und verifiziert bzw. falsifiziert. So wird das System während des gesamten Vortriebs auf korrekte Klassifizierung weitertrainiert bzw. optimiert.

Das System operiert in mehreren Phasen, die teilweise Interaktion mit dem Geologen erfordern. Der folgende Ablauf verdeutlicht die Funktionsweise (Abb. 3).

1.) Initialisierung

Samme solange TBM-Parametersätze und geologische Klasseninformation (User-Interaktion), bis in mind. zwei Klassen genügend Trainingsdaten vorhanden sind.

2.) Datenvorverarbeitung

Bereite die Daten so auf, dass sie für einen automatischen Klassifikationsalgorithmus brauchbar sind.

3.) Datenevaluierung

Baue erstmalig das statistische Modell der vorverarbeiteten Daten auf (Training). Führe eine automatische Feature Selection in Verbindung mit dem Klassifizierungsalgorithmus durch.

Ist das Klassifizierungsergebnis nicht zufriedenstellend, dann gehe zurück zur Initialisierungsphase (Schritt 1). Ist das Ergebnis zufriedenstellend, fahre mit Schritt 4 fort.

4.) Automatische Klassifizierung

Der Benutzer selektiert die TBM-Daten für den neuen zu klassifizierenden Tunnelabschnitt (User-Interaktion).

Führe automatisch die geologische Klassifizierung des selektierten Bereichs durch

5.) Verifizierung

Der Geologe ordnet die Ringe aus der automatischen Klassifizierungsphase den nach seinem Expertenwissen richtigen Klassen zu und erweitert damit den Trainingsdatenbestand (User-Interaktion).

6.) Update

Aktualisiere das statistische Modell der Daten (Retraining).

Falls das Ergebnis der Klassifizierung ungenügend war, wiederhole die Feature Selection (Schritt 3).

Falls das Ende des Tunnels noch nicht erreicht ist, gehe zurück zur automatischen Klassifizierung (Schritt 4).

[KlassifikationssystemAblauf.jpg]

Abb. 3: Funktionsweise des Klassifikationssystems.

Fig. 3: How the classification system works.

Das Klassifizierungssystem unterscheidet also in jeder Phase strikt zwischen Trainingsdaten (die Kombination aus TBM-Daten mit dazugehöriger geologischer Klasseninformation) und den Testdaten, die einer automatischen Klassifikation unterworfen werden sollen. Die Klassenvorschläge des Systems werden immer zuerst vom menschlichen Experten überprüft, bevor die automatisch klassifizierten TBM-Daten in den erweiterten Trainingsdatenpool übergehen. Der Benutzer wird also vom System als „Trainer“ benötigt, sowie zur Selektion der Tunnelbereiche, die zum Training bzw. zum automatischen Klassifizieren verwendet werden sollen. Dadurch ist die Bedienung des Systems mit minimalen Aufwand für den Benutzer verbunden und macht dadurch den Einsatz in der Praxis attraktiv. Außerdem regt die leichte Bedienbarkeit die

Experimentierfreudigkeit an, um weitere Erkenntnisse, etwa über die Relevanz von TBM-Sensoren, zu erhalten.

Schlussfolgerungen

Es wurden erstmalig computergestützte Mustererkennungs- und Lernverfahren zur automatischen Klassifizierung von geologischen Eigenschaften aus TBM-Sensordaten vorgestellt, und ihr Einsatz in einem konkreten Klassifizierungssystem dargestellt. Im Gegensatz zu bisherigen Ansätzen zeichnet sich die hier angewandte Methodik der statistischen Mustererkennung durch nahezu uneingeschränkte Anwendbarkeit, inkrementellen Wissensaufbau, Vorannahmenfreiheit, und das automatische Finden relevanter TBM-Parameter, sowie durch einfache Bedienbarkeit aus. Dem Geologen kommt während des gesamten Projekts die wichtige Bedeutung des „Trainers“ zu. Softwaretechnisch wird das Klassifizierungssystem als zusätzliche Komponente im Tunneldokumentationssystem *2doc* (11) realisiert.

Quellennachweis

1. Duda, R.O.; Hart, P.E.; Storck, D.G.: Pattern Classification. John Wiley & Sons (2001).
2. Jain, A.K.; Duin, R.P.W.; Mao, J.: Statistical Pattern Recognition: A Review. IEEE Transactions on Pattern Analysis and Machine Intelligence 22 (2000), Nr. 1, S. 4-37.
3. Mitterlechner, G.: Automatic Classification of Geology from Tunnel Boring Machine Data, Diplomarbeit (2007), Fachbereich Computerwissenschaften, Universität Salzburg.
4. Poisel, R.; Tentschert, E.; Zettler, A.H.: Rock Mass Rating and Optimized Performance of Tunnel Boring Machines Using Machine Data. Felsbau 23 (2005), Nr. 4., S. 40-48.
5. Bernardos, A.G.; Kaliampakos, D.C.: Modelling TBM Performance with Artificial Neural Networks. Tunneling and Underground Space Technology 19 (2004), Nr. 6, S. 597-605.
6. Petronio, L.; Poletto, F.: Seismic-while-drilling by Using Tunnel Boring Machine Noise. SEG Digital Library, Geophysics 15 (2002), Nr. 11, S. 40-48.
7. Yamamoto, T.; Shirasagi, S.; Yamamoto, S.; Mito, Y.; Aoki, K.: Evaluation of the Geological Condition ahead of the Tunnel Face by Geostatistical Techniques using TBM Driving Data. Tunneling and Underground Space Technology 18 (2003), Nr. 2-3, S. 213-221.
8. Bishop, C.M.: Neural Networks for Pattern Classification. Oxford University Press (1996).
9. Sapigni, M.; Berti, M.; Bethaz, E.; Busillo, A.; Cardone, G.: TBM Performance Estimation Using Rock Mass Classifications. International Journal of Rock Mechanics and Mining Sciences 39 (2002), S. 771-788.
10. Maidl, U.: FEM-Simulation und wissensbasierte Entscheidungsfindung im Rahmen des Prozesscontrollings beim hochmechanisierten Schildvortrieb. Tagungsband (Proceedings) Österreichischer Tunneltag (2004). S. 91-100.

11. Pöyry Infra GmbH Salzburg, <http://www.poyry-infra.at>

Autoren

Dipl.-Ing. Gerhard Mitterlechner, Fachbereich Computerwissenschaften, Universität Salzburg, Pöyry Infra GmbH Salzburg, Email gerhardmitterlechner@sbg.at; A.o.Univ.-Prof. Dipl.-Ing. Dr. Helmut A. Mayer, Fachbereich Computerwissenschaften, Universität Salzburg, Email helmut@cosy.sbg.ac.at; Mag. Dr. Gert Furtmüller, Pöyry Infra GmbH Salzburg, 5020 Salzburg, Email gert.furtmueller@poyry.com.