



Dipl.-Ing. Ralf Schmidt ist beim Software- und Beratungshaus PPI in Hamburg verantwortlich für Strategie und Architekturberatung im Umfeld von Business Intelligence und Business Analytics. Ein Schwerpunkt liegt auf der Implementierung von Big Data-Projekten.



Dipl.-Ök. Uwe Grünewald ist freiberuflicher Unternehmensberater und Coach, Düsseldorf. Er hat die vergangenen 25 Jahre in verschiedenen Funktionen in der IT-Branche gearbeitet – mit besonderem Fokus auf Telekommunikation.

Adaptives Projektmanagement im Controlling

Lernzentrierte Ansätze verhelfen Big Data-Projekten zum Erfolg

Ralf Schmidt und Uwe Grünewald

Nahezu jedes zweite Big Data-Projekt in deutschen Unternehmen verfehlt sein Ziel. Ein Grund liegt im klassischen Projektmanagement, das vorab definierte IT-Architekturen für bestimmte Business Cases budgetiert. Doch die IT-Anforderungen bei Big Data ändern sich häufig, ziehen damit hohe Folgekosten nach sich und lassen so viele Projekte scheitern. Abhilfe schafft ein lernzentriertes Projektmanagement.

1. Big Data: Das Gold unserer Tage

Am 24. Januar 1848 entschied sich John Sutter, eine Sägemühle an der südlichen Gabelung des American River zu errichten. Im Abfluss des Wasserrads fand einer der Konstrukteure, James Marshall, kleine Goldnuggets. Marshall und Sutter verabredeten, niemandem etwas von dem Fund zu erzählen. Doch die Geschichte vom Gold im American River machte schnell die Runde. Am 19. August desselben Jahres stand die Goldgeschichte im New York Herald und löste den berühmten California Gold Rush aus und damit eine der größten Völkerwanderungen in der US-amerikanischen Geschichte (vgl. Brands, 2008). Allein in San Francisco wuchs die Bevölkerung in nur einem Jahr von rund 1.000 auf mehr als 20.000 an. In den folgenden Jahren kamen mehr als 300.000 Glückssucher in den Sonnenstaat, um in einem unbekanntem Gebiet tief unter der Erde nach Goldschätzen zu graben. Der Traum vom Reichtum erfüllte sich jedoch nur für die wenigsten – darin ähneln sich die Goldsucher von damals und die IT-Spezialisten von heute, die in großen Datenbeständen (Big Data) ungeahnte Schätze vermuten. Sie graben keine Flusslandschaften mehr um, sondern suchen stattdessen in gigantischen Datenbergen; und diese wachsen: Bis 2020 dürften sich die im Internet und auf Unternehmensrechnern jährlich erzeugten Daten alle zwei Jahre verdoppeln. Darin enthalten sind wertvolle Informationen, bspw. zur Personalisierung von Produkten, Services und Marketingmaßnah-

men. Gleichzeitig lassen sich verschiedene Szenarien in Echtzeit analysieren, Innovationen für Produkte und Services identifizieren und Planungs- und Entscheidungsprozesse beeinflussen (vgl. King, 2013, S. 63 ff.).

Wie durchschlagend der Erfolg von Big Data sein kann, zeigt sich bereits in der Kundensegmentierung, die dem Idealbild eines „Segment of One“ immer näher kommt. Gemeint ist ein auf den einzelnen Käufer abgestimmtes Angebotsverhalten, also „die Aufteilung und Bearbeitung des Markts bis auf Individualebene“ (Hahn, 2002, S. 63). Facebook, Google etc. bauen darauf inzwischen einen Großteil ihrer Geschäftsmodelle auf. Doch auch in anderen Wirtschaftszweigen bieten sich zahlreiche Anwendungsmöglichkeiten für die Analyse großer Datenmengen an. Ein Beispiel ist das vor allem für Controller und Finanzanalytiker relevante Feld der Erkennung und Vermeidung von Betrugsfällen. Speziell Versicherungsunternehmen und die Telekommunikationsindustrie betreiben großen Aufwand, um in verfügbaren Datenbeständen nach Mustern und Anomalien zu suchen, um aktuelle Betrügereien aufzudecken und möglichst präzise potenzielle Betrugsszenarien vorherzusagen (vgl. Westphal, 2008, S. 105–346). In diesem Bereich kommen Data Scientists und ausgewählte Fachleute der jeweiligen Abteilung zusammen, um Betrugsfälle und Schwachstellen zu identifizieren.

Aktuell werten die Unternehmen nur einen Bruchteil der verfügbaren Informationen aus. Doch es deutet sich ein Wan-

Stichwörter

- Big Data
- Controlling
- IT-Management
- Projektmanagement
- Scoring

del an. Drei von vier Unternehmen planen, verbesserte Analysemöglichkeiten für verschiedene Datenbestände zu schaffen (vgl. BARC, 2014). 58 % wollen das Augenmerk dabei gezielt auf die Analyse großer Datenmengen legen. Mehr als die Hälfte möchte zudem polystrukturierte Datenquellen einbeziehen, also Informationen, die derzeit noch in unterschiedlichen Formaten vorliegen und aus unterschiedlichen Anwendungssystemen stammen. Wie der Branchenverband BITKOM ermittelt hat (vgl. BITKOM, 2014), verfügen 80 % der Unternehmen in Deutschland über genügend Daten, um Big Data-Tools sinnvoll einzusetzen. Ob diese Maßnahmen tatsächlich zu den gewünschten Erkenntnissen führen, steht jedoch auf einem ganz anderen Stück Papier. In der Beratungspraxis zeigt sich, dass jedes zweite Big Data-Projekt hinter seinen Erwartungen zurückbleibt oder sogar ganz scheitert. Denn eine Garantie, dass sich in den gespeicherten Daten wirklich ein Schatz versteckt, gibt es nicht. Stattdessen ziehen typische Big Data-Architekturen hohe Investitions- und Folgekosten nach sich, die für Unsicherheit bei der Budgetierung von Big Data-Projekten sorgen. Der Grund: Wie in Kalifornien 1848, ist unklar, ob sich in den Datenbergen ein Schatz befindet und wenn ja, wie groß der Goldklumpen ausfällt. Diese eher vagen Vorstellungen beim Heben des Schatzes erschweren die Budgetierung von IT-Projekten dieser Art. Im klassischen Projektmanagement wird nämlich ein belastbarer Business Case verlangt, der die erforderlichen Investitionen rechtfertigt. Anders ausgedrückt: Budgetentscheider wollen sich bereits vorab versichern, dass sich die Investition auszahlt – und dazu gehört, ein wirtschaftlich geeignetes Werkzeug aus-

zuwählen, um die verfügbaren Informationen auszuwerten.

2. Business Cases vorab auf die Probe stellen

In der Praxis besteht die größte Herausforderung daher darin, einen belastbaren Business Case zu entwickeln, der die hohen IT-Ausgaben rechtfertigt. Denn Big Data-Analysen erfordern Hochleistungsrechner, die mit einer sehr großen Menge an Daten möglichst in Echtzeit arbeiten können. Die Anforderungen sind vergleichbar mit der bekannten 40-Sekunden-Wette: Veteran John Richard Boyd hat US-Kampfpiloten während des Koreakriegs angeboten, jedem 40 Dollar zu bezahlen, dem es gelingt, sich innerhalb von 40 Sekunden an das Heck feindlicher Maschinen zu heften. Dabei kommt es darauf an, sekundenschnelle Entscheidungen zu treffen und nichts dem Zufall zu überlassen. Heute ist dieses Schema unter dem Namen „OODA“-Loop in der Fachliteratur geläufig: Observe-Orient-Decide-Act. Die Quintessenz lautet, dass sich Luftkämpfe und wirtschaftlicher Erfolg in diesem Punkt stark ähneln: „Dieser Zyklus [...] läuft beständig ab, und die exakte und rasche Verwertung der Daten aus der Vielzahl an Wahrnehmungen jeder einzelnen Stufe kann das eigene Handeln optimieren.“ (Klausnitzer, 2013, S. 17) Solchen Mustern, die den Zufall weitgehend ausschalten sollen, gilt das Erkenntnisinteresse im heutigen Informationszeitalter. „They now possess the data for making better business decisions“, schreibt Big Data-Experte Phil Simon (2013, S. 5) über die Identifikation möglicher Anwendungsfälle in Unternehmen. Doch diese Muster zu erkennen

und einen finanziell attraktiven Business Case zu entwickeln, ist im ersten Schritt mit einem ebenfalls gut bekannten Schema verbunden: Trial and Error. „Wichtig ist [...] eine hohe Affinität zum Forschen und Experimentieren“ (Freiknecht, 2014, S. 3), denn die erste Wahl bspw. für eine bestimmte Software erweist sich selten sofort als die richtige. Diese Prämissen laufen jedoch herkömmlichen Genehmungsverfahren zuwider und widersprechen typischen Arbeitsplatzbeschreibungen für Controller. Zwar gehört das Zusammenführen relevanter Daten zum Kerngeschäft des Controllings, doch einfaches Ausprobieren, ob sich aus den gesammelten Informationen überhaupt Zusatznutzen generieren lässt, gehört nicht dazu. Vor allem der Umgang mit riesigen, polystrukturierten Daten ist technisch anspruchsvoll und erfordert Spezialisten – und diese wiederum benötigen einen gewissen Freiraum, um einen Business Case auf den Prüfstand zu stellen, bevor die eigentliche Investitionsentscheidung fällt.

Vor der Implementierung einer Big Data-Lösung sollten die Unternehmen technische, organisatorische und prozessuale Voraussetzungen schaffen, um solche „Probegrabungen“ zu ermöglichen. Das Ziel: Die mit hohen Ausgaben verbundene Investitionsentscheidung aufzuschieben, bis die Tragfähigkeit des Big Data Business Cases erwiesen ist (vgl. Abb. 1). Das ist eine entscheidende Abweichung gegenüber dem klassischen Projektmanagement, das zunächst eine Projektskizze erfordert, anschließend ein IT-Konzept sowie eine eventuell notwendige Lieferantenauswahl für IT-Komponenten, bevor es zur Investitionsentscheidung und schließlich zur Umsetzung kommt.

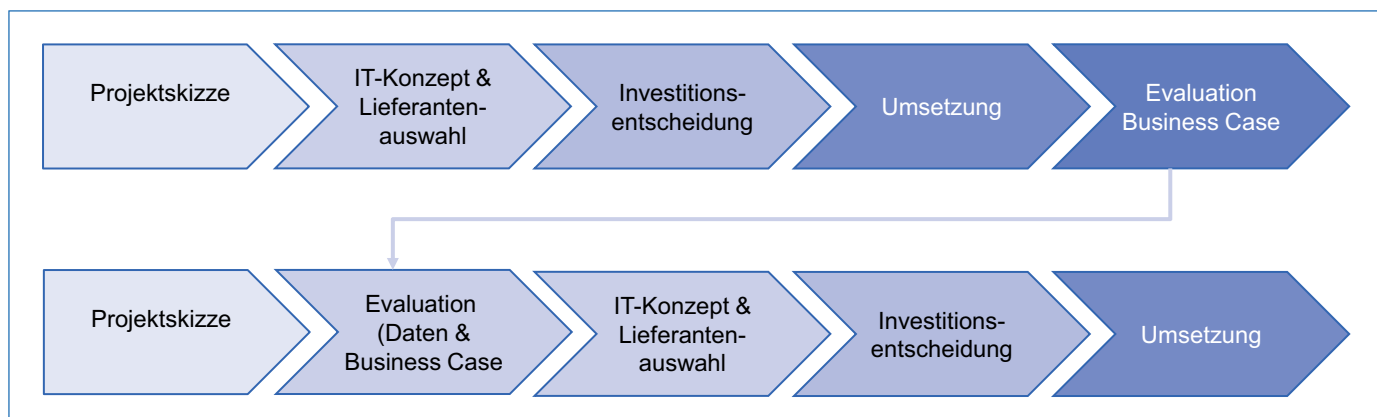


Abb. 1: Testszenarien sichern den Business Case vor der Investitionsentscheidung ab.

Traditionell besteht das Bestreben darin, bereits frühzeitig Risiken im Fach- und IT-Konzept zu eliminieren und variable Größen durch Festlegungen auf bestimmte Zielparameter verbindlich zu machen. Dies beschreibt den fachlichen Projekt-Scope (vgl. Winkelhofer, 1999, S. 11–112) – etwa zum Zweck der bereits beschriebenen Betrugserkennung. Ein anderes Beispiel aus der Finanzwelt sind Cashflow-Simulationen. In der Industrie gilt dies für Ersatzteiloptimierung und Qualitätssicherung. Anschließend erfolgen die Beschreibung von Rahmenbedingungen sowie wirtschaftliche Abschätzungen zum Kosten-Nutzen-Verhältnis. In dieser frühen Phase erhält das Projekt seine prägende Charakteristik, die sich durch Hinzunahme der IT-Prämissen schließlich weiter verfestigt und letztlich in einem vorgelagerten Evaluationsprojekt oder einer Machbarkeitsanalyse bestätigt wird. Dazu gehören eine aufwändige Analyse von Datenbeständen und die Entwicklung von Datenmodellen, damit aus der Vielzahl möglicher Technologien die passende ausgewählt werden kann. Hadoop, NoSQL, HBase oder Hive sind in diesem Zusammenhang zu nennen (vgl. Freiknecht, 2014, S. 19 ff.). Diese Tools sind zudem mit Blick auf ihren Wertbeitrag bei der Umsetzung fachlicher Anforderungen und die Bewertung technischer und fachlicher Lieferanten für das Projekt zu berücksichtigen. Was die IT betrifft, so werden die Grenzen, in denen sich das Projekt fachlich noch verändern kann, täglich enger fixiert – der Handlungsspielraum für Anpassungen verkleinert sich.

Eine im Rahmen der fachlichen Umsetzungsplanungen zu spät gewonnene Erkenntnis hinsichtlich Datenanforderungen oder auch des Zielbildes, läuft nun jedoch Gefahr, nicht mehr im Rahmen des aktuellen Projekts abgehandelt werden zu können. Hinzu kommt, dass die fachlichen Vorstellungen in dieser Projektphase erfahrungsgemäß auf IT-Limitierungen stoßen, etwa hinsichtlich Laufzeiten, Datenverfügbarkeit oder Datengranularität, die den ursprünglich vorgesehenen Projekt-Scope weiter begrenzen. Dabei unterschätzen die Verantwortlichen zudem einen ganz entscheidenden Einflussfaktor auf das Projekt: Lieferanten. Als typisches Beispiel in diesem Kontext gelten Regallizenzen, die das ursprünglich benötigte und vom Kunden gewünschte Softwarepaket erweitern. Das

Produkt kommt als Dreingabe in das Projekt und schränkt, da es zunächst nicht benötigt wird, den finanziellen Freiraum unter Umständen nochmals ein. So erweisen sich auf den ersten Blick nützliche Features als Hindernis. Das ist insb. dann der Fall, wenn die Projektbeteiligten für die Nutzung dieses Features weitere Einschränkungen oder Zugeständnisse bei der IT-Architektur machen. Eine weitere Gefahr lauert bei nachträglichen Versuchen, das Projekt trotz finanzieller Einschränkungen zu irgendeinem verwertbaren Ergebnis zu führen, damit das eingesetzte Budget nicht vollends verlorengeht.

3. Herkömmliche Projektmethoden

Die Investitionsentscheidung markiert im Genehmigungsprozess den „Point of No Return“. Erstmals wird tatsächlich Geld ausgegeben, um Hardware und Software für das geplante Big Data-Projekt anzuschaffen. An dieser Stelle tritt das maßgebliche und für den Business Case erfolgskritische Merkmal herkömmlicher Projektmethoden zutage: Erhebliche Investitionen in ein IT-Projekt auf Basis einer nur im Präsentationsmodus oder in einem abgegrenzten „Proof of Concept“ erprobten konzeptionellen Grundlage. Hinzu kommt, dass die aktuelle Praxiswelt abseits von *Facebook*, *Google* oder *Yahoo* mit ihren datenintensiven Anwendungen kaum belastbare Referenzimplementierungen bereithält. Das lädt zu Kompromissen aus politischen, organisatorischen und technischen Gründen ein. Insofern steht die Praxis-tauglichkeit des Gesamtkonzepts gleich in doppeltem Sinne auf dem Prüfstand. Entsprechend groß fällt die Ernüchterung aus, wenn es zu Schwierigkeiten im Projektverlauf kommt. Im Projektalltag treten vor allem folgende Hürden auf:

- Annahmen über die Hardware-Leistungsfähigkeit, die sich im Nachhinein als falsch oder zumindest unzureichend erweisen
- Mängel bei der Datenqualität, die sich im laufenden Projekt als gravierend herausstellen
- Datenbestände, die sich zwar komprimieren lassen, jedoch dann inkompatibel sind zu der gewählten Lösung für die Datenhaltung

- Angeschaffte Business Solutions entpuppen sich als offenes und hochentwickeltes Entwicklungsframework. Das zieht ungeplante Zusatzaufwände nach sich, da eine Business Solution üblicherweise ein klar umrissenes Geschäftsproblem möglichst direkt löst, während Entwicklungsframeworks erst durch teils umfassende Konfiguration und Entwicklungsleistung den gewünschten Erfolg bringt

Projektverantwortliche aus der Praxis können diese Liste beliebig fortsetzen, denn „die *technischen* Aspekte des Big-Data-Trends werden nur selten in ausreichendem Detailgrad diskutiert“ (Freiknecht, 2014, S. 1) zumal Big Data mehr als nur einen einzigen Technologietrend beschreibt. Vielmehr basiert der Umgang mit Big Data auf vielen verschiedenen Ansätzen. Erst im Zusammenspiel entfalten die Technologien ihr gesamtes Potenzial. Änderungen in diese Kompositionen ziehen daher unmittelbare Folgekosten nach sich und wirken sich direkt auf den Business Case aus – und bringen damit schlimmstenfalls die Gesamtbilanz des Projekts in Schieflage. Viele Projektleiter wollen jetzt das Projekt trotzdem in der Erfolgsspur halten und setzen alle zur Verfügung stehenden Mittel und Methoden ein, um dies zu erreichen. Die bereits erwähnte Fixierung sowohl der fachlichen, technischen als auch finanziellen Rahmenbedingungen engen den Handlungsspielraum jedoch erkennbar ein, vor allem wegen der hohen Anfangsinvestitionen in die Big Data-Ausstattung. Damit ist ein gängiger Ausweg im klassischen Projektmanagement verstellt: Eine Ausweitung des Projekt-Scope auf fachlich artverwandte, im Rahmen des bisherigen Projekts als sinnvoll erkannte Ideen. Die zuvor auf den Business Case zugeschnittene IT-Architektur verhindert diese flexible Anpassung. Projektbezogene Lizenzierungen von Software erweisen sich beispielsweise als finanzieller Engpass, wenn es darum geht, eine kostenneutrale Ausweitung des Projekts auf zusätzliche Fachthemen zu erzielen. In der Beratungspraxis zeigt sich, dass vor allem vier Charakteristika im herkömmlichen Projektmanagement dafür verantwortlich sind, Big Data-Projekt auszubremsen:

- Ein unumstößlich definiertes, fachliches Zielbild
- Frühe Fixierung auf eine bestimmte IT-Architektur

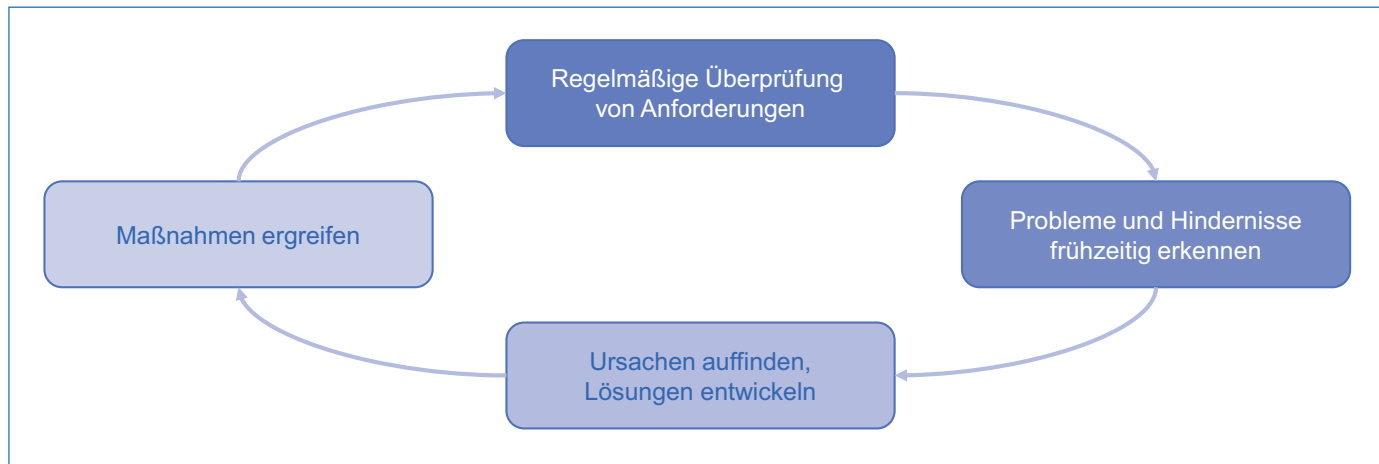


Abb. 2: Schemadarstellung des Scrum-Kreislaufs in agilen Projekten (vgl. Pichler, 2008, S. 3)

- Hohe Anfangsinvestitionen in frühen Projektphasen
- Starres Projektdesign, das fachliche und technische Änderungen im Rahmen des bestehenden Business Cases kaum zulässt

Der klassische Werkzeugkasten ist darauf ausgerichtet, diese Aspekte risikominimierend im Sinne des Projekts zu managen und dies innerhalb eines vorgegebenen Budgets und innerhalb definierter Zeitfenster abzuschließen. Ein Scheitern oder Neujustieren erscheint in diesem Kontext als ein Störfaktor, der als unwillkommen wahrgenommen wird, obwohl darin Hinweise für einen erfolgreichen Projekt-Scope für Big Data stecken.

4. Agile Methoden begünstigen Big Data

Unternehmen, die bei dieser Methodik stehenbleiben, verschenken wertvolles Potenzial. Zwar haben sich die beschriebenen Charakteristika auch, zumindest teilweise, in Big Data-Projekten bewährt, bspw. lässt sich aus strukturierten Datenhaushalten eine Vielzahl von Erkenntnissen gewinnen und produktiv nutzbar machen. Eine langjährige Beschäftigung mit diesen Daten, etwa im Controlling, im Kundenmanagement oder im Marketing, zeigt jedoch, dass durch ausschließliche Erweiterung des Datenhaushalts bei einer unveränderten Methodik kaum zusätzlicher Mehrwert entsteht. Vielmehr läuft dieser Ansatz auf eine Absicherung bereits gewonnener Erkenntnisse oder einer nur graduellen Erweiterung bereits vorhandener analytischer Methoden hin-

aus. Big Data steckt dann in einer Sackgasse, da dies keine oder nur geringwertige Einsichten bietet. Dabei ist Big Data jedoch gerade mit der Hoffnung verbunden gewesen, neue Erkenntnisse hervorzubringen. Ein Blick auf die technischen Möglichkeiten genügt: Statt auf aggregierten Daten lässt sich auf Rohdaten arbeiten. Bisher vor allem wegen ihrer Größe kaum zu beherrschende Datenmengen lassen sich nun einbinden. Und statt auf nächtliche Batch-Läufe zu warten, stehen Datenanalysen in Echtzeit zur Verfügung. Der Vorteil im Controlling liegt auf der Hand: Automatische Mustererkennung, Frühwarnsysteme, Schwellwertberechnungen und ein intelligentes Berichtswesen, all diese Anwendungsbereiche bleiben den Unternehmen verschlossen, die weiterhin einen starren, risikoaversen Projektansatz verfolgen.

Stattdessen sollten die Unternehmen auf agile Methoden umsteigen, damit sich fachliche Thesen innerhalb eines Projekts schnell und flexibel untersuchen lassen, statt auf vorab fixierten Zielbildern zu beharren. Auf den Punkt gebracht bedeutet dies: „Mit einem zu Projektbeginn erstellten Projektplan wird man nach agiler Sichtweise nicht weit kommen.“ (Andresen, 2014, S. 5) Entscheidend sind vielmehr Retrospektiven auf den Projektverlauf, die auch Einfluss auf die technischen und fachlichen Grundlagen nehmen. Einen besonders bekannten Methodenbaukasten stellt *Scrum* dar sowie speziell für IT-Projekte *Kanban*. Beiden ist ein lernzentrierter Ansatz gemeinsam, der auf kurze Arbeitszyklen abzielt. Dies erlaubt, frühzeitig Probleme zu identifizieren und den gesamten Projektablauf daraufhin auszurichten, rechtzeitig auf-

tretende Schwierigkeiten zu erkennen, zu eliminieren und sich bereits im folgenden Arbeitszyklus an den neu gewonnenen Erkenntnissen zu orientieren. Im Prinzip handelt es sich dabei um einen Kreislauf ständiger Anpassung (vgl. Abb. 2), der dem linearen Verlauf klassischer Projektmethoden zuwiderläuft. Das zeigt sich vor allem in der Wahrnehmung plötzlich auftauchender Probleme. Klassische Methoden nehmen solche Störungen als Gefahr wahr, die das Projekt bedrohen. Hinter einem agilen Ansatz steckt dagegen die Philosophie, solche Ereignisse als Erkenntnisgewinn in den weiteren Projektverlauf einzuspeisen. Das gilt auch für Potenziale, die sich erst während des Projektverlaufs offenbaren. So erlauben Big Data-Tools, auf Datenbestände zuzugreifen, auf die bisher, vor allem wegen technischer Limitierungen, nicht zugegriffen werden konnte. Bei Projektstart lässt sich daher per se kaum ausschließen, dass neue Erkenntnisse den ursprünglichen Projekt-Scope erweitern. Dafür müssen flexible Methoden bereitstehen, um das Projekt neu zu justieren.

Der lernzentrierte Ansatz führt zu einer neuen Sichtweise auf das Gesamtprojekt. Angelehnt an die Kriterien für „Hoch Adaptive Projekte“ (H.A.P-Modell, vgl. Borgert, 2013, S. 51–80) ergeben sich sechs Charakteristika für Erfolg auch im Big Data-Umfeld:

- Untersuchung fachlicher Thesen innerhalb eines zeitlich definierten Rahmens mit echten Daten unter möglichst produktionsnahen Bedingungen
- Entscheidung für eine IT-Architektur erst nach Vorliegen der Untersuchungsergebnisse

- Verlagerung der Investitionsentscheidung auf einen Zeitpunkt, zu dem der Business Case bereits umfassend validiert und abgesichert ist (siehe Abb. 1)
- Verringerung der finanziellen Eintrittsschwelle, um auch bei falsifizierten Thesen weiterhin proaktiv handeln zu können
- Adaptives Projektmanagement, mit dem auch unter der Bedingung einer vollständigen und fachlichen Neuausrichtung des Projekts noch ein erfolgreicher Abschluss möglich ist
- Eine Methodik, die erlaubt, ein erfolgversprechendes Setup kurzfristig in ein reguläres Projekt und nachfolgend in die Produktion zu überführen

Zahlreiche Erfahrungsberichte aus der Big Data-Praxis bestätigen diese Anforderungen. Allein die Komplexität entsprechender IT-Projekte und der Umgang mit zuvor ungenutztem Material erzwingen geradezu, dass sich noch zur Laufzeit Anpassungsbedarfe ergeben, die sich auf Projekt-Scope und anfängliche Annahmen auswirken. In der Theorie sind diese Erkenntnisse durch Begriffe wie Adaptivität und Resilienz (vgl. *Borgert*, 2013) bereits fest verankert. Die gute Nachricht: Eine agile Projektmanagementmethode einzuführen ist auch im Bereich Controlling vor allem ein Ausbildungs- und Prozessthema, das sich relativ schnell umsetzen lässt. Einige der aufgeführten Punkte sind zudem in vielen Unternehmen bereits implementiert und bedürfen nur kleiner Anpassungen, um sie agiler zu machen. Das ist eine Aufgabe für das Change Management. Durch Schulungen lässt sich die Veränderung darüber hinaus professionell begleiten. Zertifizierungen schaffen dabei zusätzliche Sicherheit, wenn es darum geht, agile Methoden nachhaltig einzuführen und möglicherweise auch in anderen als nur Big Data-Projekten anzuwenden.

5. Drei Weichenstellungen für Big Data-Erfolge

Im agilen Umfeld von Big Data-Projekten hat sich zudem bewährt, fachliche Thesen im Voraus in einem produktionsnahen Umfeld zu validieren. Stattdessen schaffen viele Unternehmen für einzelne Testprojekte oder „Proofs of Concept“ häufig eigene Datenhaushalte. Ein IT-af-

finer Controller ist dann damit beschäftigt, dafür meist in Handarbeit geeignete Daten zu identifizieren und zusammenzutragen. In mühsamen Einzelschritten müssen Datenqualität, Datenanreicherung und -bereinigung sichergestellt sein – so die reine Lehre in gängigen IT-Projekten. Allerdings entsteht auf diese Weise ein hochoptimierter Datenbestand, der während des „Proofs of Concept“ fast automatisch zielführende Ergebnisse liefert. Schließlich sind die Daten vorab zu genau diesem Zweck ausgewählt worden. Im produktiven Umfeld nimmt die Ergebnisqualität dann schlagartig ab, da die zuvor per Hand hergestellte Datenqualität im industriellen Maßstab für Big Data kaum zu gewährleisten ist. Entscheidend ist daher, dass das Projektteam mit realen Datenbeständen arbeiten kann, um eine bestmögliche Einschätzung darüber zu erlangen, ob der erwartete Nutzen im Produktivbetrieb tatsächlich entsteht. Die beschriebenen Big Data-„Probegrabungen“ bleiben auf diese Weise unverfälscht. Erfahrungen aus erfolgreich abgeschlossenen Projekten belegen, dass die realitätsnahe Beurteilung der Qualität des Gesamtdatenbestands erfolgskritisch ist. Bereits während der Testphasen Methoden zur automatisierten Qualitätssicherung des Bestands zu entwickeln, erweist sich daher als besonders lohnend.

Darüber hinaus zeigt sich im Projektalltag immer wieder, dass zu den nötigen Veränderungen auf organisatorischer Ebene auch eine veränderte Fehlerkultur gehört. Wie bereits beschrieben, macht das Testen und Ausprobieren von fachlichen und technischen Thesen einen ganz wesentlichen Charakterzug von Big Data-Projekten aus. Natürlich kann dabei nicht jede Idee ein Volltreffer sein. Eine Fehlerkultur, die den Fehlschlag als Erkenntnisgewinn akzeptiert, ist an dieser Stelle deshalb von zentraler Bedeutung. Vorbild dafür sind so genannte „High Reliability Organizations“ (HRO), in denen kritische Fehler potenziell tödliche Folgen haben können. Beinahekatastrophen gelten daher nicht als Beweis für Misserfolg, wie im herkömmlichen Projektmanagement üblich, sondern als Hinweis auf Störungen im System. Das bedeutet, eine gewisse „Notwendigkeit von organisationaler Flexibilität im Umgang mit Unerwartetem; und zwar vor, während und nach dessen Realisation“ (*Duchek, Klaufner*, 2013, S. 52) zu akzeptieren. Insbesondere in einem wirtschaftlich he-

rausfordernden Thema wie Big Data ist diese Flexibilität ungemein wichtig – genauso wie eine hohe Fehlertoleranz. Das gilt ganz wesentlich auch bei der Gestaltung des technischen und fachlichen Projektrahmens.

Eng damit verknüpft ist die Frage nach der wirtschaftlichen Eintrittsschwelle. Wer von vornherein weiß, dass Fehler passieren, muss seine Kostenstrukturen im Griff haben. So bietet Big Data gerade im Controlling die Möglichkeit, eine Vielzahl unterschiedlicher Datenquellen in die Analyse einzubeziehen. Das können Maschinendaten, Kundendaten, elektronische Postfächer, Datensätze aus Dokumentenmanagementsystemen oder sozialen Medien sein. In den seltensten Fällen hat der Schöpfer dieser Datenbestände damit rechnen können, dass diese Informationen eines Tages in einem analytischen Folgeprozess verwendet werden. Angesichts der hohen Investitionskosten in eine Big Data-Architektur ist darüber hinaus offen, wie oft das Controlling in der Lage ist, Tests mit anderen Tools durchzuführen, neue Daten hinzuzunehmen oder sogar den analytischen Prozess komplett neu zu denken. Davon profitieren Big Data-Projekte immens, folglich müssen möglichst viele Ideen in möglichst hoher Frequenz getestet werden. Eine Begrenzung des finanziellen Einsatzes ist trotz des bisher Gesagten jedoch unabdingbar. Eine Lösung besteht in gemieteten Big Data-Architekturen, die mit einem wirtschaftlich überschaubaren Risiko erlauben, Probegrabungen im Rahmen eines Evaluationsprojekts (Big Data Evaluation Package) durchzuführen. Damit ist die Anforderung erfüllt, erst bei nachgewiesenem Erfolg die Investitionsentscheidung zu treffen und das Projekt umfassend auszurollen.

Keywords

- Big Data
- Controlling
- IT Management
- Project Management
- Scoring

Summary

Almost every second Big Data project in Germany misses its targets due to rigid definitions of business cases and thereof deduced IT architectures. In fact, the requirements of a Big Data scenario often change throughout a project period and render previous as-

sumptions of the necessary IT architecture useless. This leads to high consequential charges. A forward-looking Project Management provides relief.

Literatur

Andresen, J., Retrospektiven in agilen Projekten: Ablauf, Regeln und Methodenbausteine, München 2014.

BARC-Institut, Big Data Analytics: Auf dem Weg zur datengetriebenen Wirtschaft, Würzburg 2014.

BITKOM, Potenziale und Einsatz von Big Data, Berlin 2014.

Borgert, S., Resilienz im Projektmanagement, Wiesbaden 2013.

Brands, H.W., The Age of Gold: The California Gold Rush and the New American Dream, Austin (Texas) 2008.

Duchek, S./Klaußner, S., Temporärer Umgang mit Unerwartetem, in: Koch, J./Sydow, J. (Hrsg.), Organisation von Temporalität und Temporärem, Managementforschung 23, S. 49–82, Wiesbaden 2013.

Freiknecht, J., Big Data in der Praxis: Lösungen mit Hadoop, HBase und Hive. Daten speichern, aufbereiten, visualisieren, München 2014.

Hahn, C. H., Segmentspezifische Kundenzufriedenheitsanalyse: neue Ansätze zur Segmentierung von Märkten, Wiesbaden 2002.

King, S., Big Data: Potenzial und Barrieren der Nutzung im Unternehmenskontext, Innsbruck 2013.

Klausnitzer, R., Das Ende des Zufalls: Wie Big Data uns und unser Leben vorhersehbar macht, Salzburg 2013.

Pichler, R., Scrum: Agiles Projektmanagement erfolgreich einsetzen, Heidelberg 2008.

Simon, P., Too Big to Ignore: The Business Case for Big Data, Hoboken (New Jersey) 2013.

Westphal, C., Data Mining for Intelligence, Fraud & Criminal Detection: Advanced Analytics & Information Sharing Technologies, Boca Raton (Florida) 2008.

Winkelhofer, G., Management- und Projektmethoden: Ein Leitfaden für IT, Organisation und Unternehmensentwicklung, 3. Aufl., Stuttgart 1999.

Literaturtipps aus dem **Online-Archiv** der CONTROLLING:

- Wolfgang Becker und Mathias Hofmann, Projektmanagement in deutschen Unternehmen – Empirische Befunde und Implikationen für die Wirtschaftspraxis, Ausgabe 10/2010, S. 557–564.
- Dietmar Schön/Marc Diederichs und Volker Busch, Chancen- und Risikomanagement im Projektgeschäft – Transparenz durch ein DV-gestütztes Frühwarninformationssystem, Ausgabe 7/2001, S. 379–387.
- Carsten Glohr, IT-Kennzahlen für den CIO, Ausgabe 3/2006, S. 149–156.