

Moderne Frühwarn- und Prognosesysteme für Unternehmensplanung und Risikomanagement

Dr. Werner Gleißner, Leinfelden-Echterdingen und
Dr. Karsten Füser, Stuttgart

1. Bedeutung von Frühwarn- und Prognosesystemen

1.1 Ziele, Definition und Systematisierung

Frühwarnsysteme sind eine spezielle Art von Informationssystemen, die darauf abzielen, zukünftige Entwicklungen und Ereignisse mit Bedeutung für das Unternehmen vorab – d.h. vor Eintritt eines Schadens – zu erkennen. Damit soll die Möglichkeit geschaffen werden, diese (i.d.R. negativen) Entwicklungen durch geeignete präventive Maßnahmen zu antizipieren. Frühwarnsysteme verschaffen dem Unternehmen letztlich also Zeit für adäquate Reaktionen und verbessern so die Steuerbarkeit des Unternehmens, was zu einer günstigeren Entwicklung des Unternehmenswertes als letztendlicher Zielgröße vieler Unternehmen bzw. seiner maßgeblichen Determinanten beiträgt.

Anstelle von Frühwarnsystemen spricht man weitgehend synonym auch von Frühaufklärungssystemen oder Prognosesystemen.

In Zukunft wird eine neue Anforderung an Frühwarnsystemen immer größere Bedeutung gewinnen: Während es in der Vergangenheit „nur“ darum ging die zukünftige Entwicklung interessierender Zielvariablen, wie den Umsatz oder den Gewinn, besser *vorhersagen* zu können, werden zukünftige Frühwarnsysteme oft auch die Entwicklung dieser Zielvariablen *erklären* müssen.

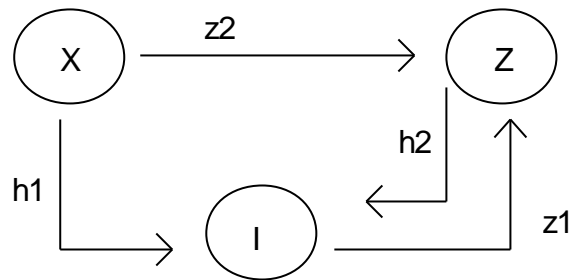
Solche Frühwarnsysteme sind keinesfalls eine „Black-Box“; sie werden statt dessen transparent und zeigen die strukturellen Zusammenhänge auf, die Grundlage einer durch sie erstellten Prognose sind. Damit werden sie stärker als bisher einer kritischen Diskussion zugänglich und erlauben es, die eigenen Vorstellungen über die Ursache-Wirkungs-Zusammenhänge zu diskutieren und schließlich sogar anhand von empirischen Daten zu überprüfen. Frühwarnsysteme dienen damit zwangsläufig nicht mehr ausschließlich dazu, möglichst früh und möglichst exakt zukünftige Entwicklungen zu prognostizieren, sondern sie fördern zudem eine kontinuierliche Auseinandersetzung der Mitarbeiter mit den wahrgenommenen Veränderungen innerhalb und außerhalb des Unternehmens sowie den dahinter vermuteten Ursache-Wirkungs-Beziehungen. Schon beim Aufbau von Frühwarnsystemen lernt der Anwender auch im erheblichen Umfang über die strukturellen, kausalen Zusammenhänge; das Verständnis für die Umwelt des Unternehmens steigt. Die Wirkungen des eigenen Handelns werden damit ebenso transparenter wie die Wirkungswege exogener Störungen auf die Unternehmensziele. Schon mit dem Aufbau solcher Frühwarnsysteme ist damit ein Wissensgewinn verbunden, der zu einer besseren Fundierung unternehmerischer Entscheidungen beiträgt und so auch die Grundlage für moderne betriebliche Steuerungssysteme – wie die Balanced Scorecard – legt.

Fazit: Frühwarnsysteme sollten also die Eigenschaft haben – unter Ausnutzung heute verfügbarer Informationen –

- möglichst früh,
- möglichst präzise und
- möglichst nachvollziehbar

die Zukunft einer für das Unternehmen relevanten Variable vorherzusagen und darüber hinaus die Mitarbeiter für den kritischen Umgang mit wahrgenommenen Veränderungen im Unternehmen und seinem Umfeld sensibilisieren.

Etwas vereinfachend kann man die Bedeutung von Frühwarnsystemen im folgenden formalen Modell einer gezielten Unternehmenssteuerung darstellen:



- Z : Unternehmensziele
- X : exogene Störungen, welche die Zielerreichung beeinflussen
- I : Aktivitäten (Instrumente, Maßnahmen) des Unternehmens
- $h1, h2$: (heuristische) Verhaltensregeln des Entscheiders bezügl. Einsatz von I
- $z1, z2$: Wirkungsbeziehungen (Zielvariable Z in Abhängigkeit von X und I)

Abb. 1: Wirkungsdreieck

Dieses Modell zeigt ein "Wirkungsdreieck" zwischen unternehmerischen Maßnahmen (I), Unternehmenszielen (Z) und exogenen Störungen (X), die von "außen" kommend die Zielerreichung beeinflussen. Die Entscheidungen bzw. Maßnahmen hängen sowohl von den momentan erkennbaren Störungen (X) als auch von dem momentanen Grad der Zielerreichung (Z) ab. Eine unmittelbare Reaktion auf Störungen X ist sinnvoll, weil diese zukünftig die Zielerreichung beeinflussen und man dann nicht erst warten muss, bis diese Konsequenzen tatsächlich eingetreten sind.

Die Aufgabe eines Frühwarnsystems ist es, bereits heute die exogenen Störungen (X) zu erkennen, daraus Schlussfolgerungen für die zukünftige Entwicklung der Ziele Z abzuleiten und so die Grundlage für einen zielorientierten Einsatz der betrieblichen Steuerungsinstrumente zu schaffen. Letztendlich tragen Frühwarnsysteme damit zu einer Reduzierung der möglichen "Überraschungen" der Zukunft – also von Risiken – bei¹.

Krystek und Müller-Stewes unterscheiden drei Generationen von Frühaufklärungsansätzen:

Frühaufklärungsansätze der ersten Generation:

Erste Frühaufklärungsansätze finden sich im angloamerikanischen Raum seit Mitte der 60er-Jahre. Sie waren in erster Linie Berichtssysteme, die "Ausnahmemeldungen" weiterleiteten. Seit den 70er-Jahren werden als Frühwarnsysteme diejenigen (computergestützten) Planungs- und Kontrollsysteme bezeichnet, die bei Unter- oder Überschreiten definierter Schwellenwerte von betrieblichen Kennzahlen Warnmeldungen auslösen. Auch die in modernen Controlling-Konzeptionen selbstverständlichen unterjährigen Planungshochrechnungen, die Abweichungen zwischen ursprünglicher Planung und hochgerechneten, voraussichtlichem Ist-Wert anzeigen, gehören in diese Kategorie der Frühwarnsysteme.

¹ Definition: Risiken sind die aus der Ungewissheit der Zukunft resultierenden, durch "zufällige" Störungen verursachten Gefahren, geplante Ziele zu verfehlen.

Frühaufklärungsansätze der zweiten Generation:

Indikatoren (leading indicators), die Informationen über die zukünftige Entwicklung der eigentlichen Zielgrößen liefern und damit Prognosen ermöglichen, sind die zentralen Elemente dieser zweiten Generation, die seit Ende der 70er-Jahre an Bedeutung gewinnen². Von der ersten Generation unterscheiden sich diese Frühaufklärungsansätze insbesondere durch die systematische Suche nach relevanten Entwicklungen inner- und außerhalb des Unternehmens.

Frühaufklärungsansätze der dritten Generation:

Die Frühaufklärungsansätze der ersten und zweiten Generation befassten sich primär mit finanziellen Zielgrößen. Die entscheidenden Impulse für die Entwicklung der an den Erfolgspotenzialen eines Unternehmens orientierten Frühaufklärung gingen durch das von Igor Ansoff³ entwickelte Konzept der "schwachen Signale" aus. Im deutschsprachigen Raum begann die Beschäftigung mit solcher strategischer Frühaufklärung etwa zeitgleich mit dem Ausbau der indikatororientierten Frühaufklärungsansätze.

1.2 Betriebswirtschaftliche Bedeutung von Frühwarn- und Prognosesysteme

Da die Qualität unternehmerischer Entscheidungen im Wesentlichen von der Qualität der zugrundeliegenden Informationen abhängt, stellt die überdurchschnittliche Fähigkeit eines Unternehmens, relevante Informationen zu beschaffen und optimal aufzubereiten, einen wesentlichen Wettbewerbsvorteil dar. Oft werden prinzipiell verfügbare Informationen aber nicht ausreichend ausgewertet; bei manchen Unternehmensführungen scheint noch immer "intuitiver Blindflug" vorherrschend zu sein.

Für fast alle unternehmerischen Entscheidungen werden Informationen über die erwartete Zukunftsentwicklung bestimmter Einflussfaktoren – also Prognosen – benötigt. Beispielsweise ist eine fundierte Investitionsplanung ohne Informationen über die zukünftige Entwicklung von Absatzmengen, Preisen, Kosten und Zinsen nicht möglich. Die Strategische Unternehmensplanung benötigt Informationen über zukünftige Marktbedingungen und Änderungen im Konsumentenverhalten. Bei der (operativen) Bestellmengenplanung benötigt man Prognosen über den Lagerabgang der nächsten Tage oder Wochen.

Für diese Aufgabenstellungen gibt es sehr unterschiedliche Prognoseverfahren. Im **strategischen Bereich** – also bei langfristigen Prognosen – bietet es sich beispielsweise an, im Rahmen ausführlicher strategischer Planungsrunden mit der Unternehmensführung und neutralen, unternehmensexternen Experten (mittels Brainstorming- oder Delphi-Verfahren) alternative Zukunftsszenarien zu entwerfen und über deren Eintrittswahrscheinlichkeit zu diskutieren (vgl. zu den "qualitativen Methoden" Abschnitt 2.1). Weitere Verfahren sind Simulationsmodelle, Entscheidungsbaumverfahren oder die Trend-Impact-Analyse.

Im **operativen Bereich** können verstärkt formale (mathematische) Verfahren eingesetzt werden, weil bei kurzfristigen (nicht so sehr bei langfristigen) Prognosen strukturelle Änderungen der kausalen Zusammenhänge selten sind (vgl. zu den hier dominierenden "quantitativen Methoden" Abschnitt 2.2).

² Vgl. Kühn/ Walliser, in: Die Unternehmung, 1978 S. 223ff.

³ Vgl. Ansoff in: Zeitschrift für betriebswirtschaftliche Forschung, 1976 S. 129ff.

1.3 Frühwarn- und Prognosesysteme im Kontext des Risikomanagements

Eine hohe Bedeutung haben Frühwarnsysteme auch im Kontext des Risikomanagements. Die Frühwarnsysteme müssen gemäß dem Kontroll- und Transparenzgesetz im Unternehmensbereich (KonTraG) zumindest geeignet sein, bestandsgefährdende Risiken früh zu erkennen (vgl. § 91 Aktiengesetz). Da Frühwarnsysteme damit letztlich auch Handlungen (Gegenmaßnahmen) der jeweiligen Entscheidungsträger initiieren, schaffen sie nicht nur Transparenz, sondern sind zugleich Instrumente der Risikobewältigung.

Der Sinn der Frühwarnsysteme ist hierbei insbesondere darin zu sehen, dass das Unternehmen durch bessere Prognosen der Zukunft auf eine so vorhergesagte Störung rechtzeitig durch gezielte Gegenmaßnahmen reagiert ("technokratischer Ansatz"). Beispielsweise könnte man durch Messungen die Wahrscheinlichkeit eines Maschinenausfalls vorhersagen und beim Überschreiten einer bestimmten Ausfallwahrscheinlichkeit Wartungsmaßnahmen einleiten.

Gezielte Steuerungsmaßnahmen, die auf die Vorhersage bestimmter, konkreter Entwicklungen – und damit auf Frühwarnsystemen – basieren, sind jedoch nicht die einzige Möglichkeit der Risikobewältigung. Wenn man eine bestimmte zukünftige Störung nicht (präzise genug) vorhersagen kann, lässt sich alternativ die Struktur eines Unternehmens oder Unternehmensteils so ändern, dass eine beliebige, nicht vorhergesehene Störung ohne schwerwiegende Folgen bleibt ("flexibler Ansatz"). Wenn man im genannten Beispiel den Ausfall einer Maschine nicht vorhersagen kann, könnte man einfach eine zweite Maschine (redundantes System) anschaffen, die im Störfall aktiviert wird. Denkbar ist zudem, gezielt Gegenpositionen zu bestimmten Risiken aufzubauen (Hedging), die bewirken, dass genau beim Eintreten eines Risikos (z.B. eines die Finanzierung verteuernenden Zinsanstiegs) an anderer Stelle Gewinne erzielt werden (z.B. Wertzuwachs einer Verkaufsoption auf Bundesanleihen). In einigen Fällen ist es schließlich möglich, durch das Ausüben von Macht eine bisher als zufällig bzw. exogen erscheinende Störung selbst beherrschbar zu machen, d.h. zu "endogenisieren".

2. Methodische Grundlagen von Frühwarnsystemen

2.1 Qualitative Methoden

Die qualitativen Frühwarnsysteme, die beispielsweise auf der Auswertung sogenannter "schwacher Signale" gemäß Ansoff basieren, sind nicht statistisch bzw. ökonometrisch untermauert. Durch eine mehr oder minder systematische Auswertung von Informationen aus dem Unternehmen und vor allen Dingen aus seinem Umfeld durch Fachexperten sollen maßgebliche Entwicklungen früh erkannt werden. Diese qualitativen Frühwarnsysteme dienen dabei beispielsweise auch der durch das KonTraG und in weiterer Verfeinerung durch die im IDW-Prüfungsstandard 340 vorgeschriebene Identifikation neuer Risiken. Qualitative Frühwarnsysteme nutzen unterschiedlichste Arten von Informationen:

- Marktinformationen (z.B. Branchentrends, Veröffentlichungen über Wettbewerber)
- technologische Informationen (z.B. aus Messen, Hochschulen..) oder auch z.B.
- politische, gesellschaftliche und rechtliche Informationen.

Die Auswertung solcher qualitativer Informationen stützt sich maßgeblich auf die Zusammenarbeit von Fachexperten, die aus den vorliegenden Informationen die richtigen Schlussfolgerungen ziehen können. Die Standardisierbarkeit ist daher nur eingeschränkt möglich. Festlegen lässt sich jedoch, welche Informationsquellen in welchem Turnus auf jeden Fall auszuwerten sind. Besonders geeignet sind qualitative Frühwarnsysteme bei Langfristprognosen, wenn es beispielsweise darum geht, strukturelle Veränderungen zu erkennen und zu interpretieren.

Grundsätzlich besteht bei diesen Prognosen aber die nicht zu unterschätzende Gefahr, dass den Menschen systematische, psychologisch bedingte Fehleinschätzungen unterlaufen. Menschen haben beispielsweise – wie Psychologen immer wieder belegt haben – erhebliche Probleme bei der Schätzung von Wahrscheinlichkeiten und der Prognose von Wachstumsprozessen⁴.

2.2 Traditionelle statistische Methoden und ihre Schwächen

Im Gegensatz zu den qualitativen Prognosesystemen sind die quantitativen Prognosesysteme sehr systematisch und damit i.d.R. auch nachvollziehbar. Sie nutzen statistische und ökonometrische Verfahren. Dabei werden bestimmte festgelegte quantitative Informationen (Zeitreihen) ausgewertet, um damit Schlussfolgerungen für bestimmte Zielvariablen (z.B. die Umsatzentwicklung) gewinnen zu können. Typische Informationen, die im Rahmen von quantitativen Frühwarnsystemen verwendet werden, sind z.B. der Geschäfts- und Konsumklimaindex, Zinsen und Währungskurse oder Änderungen der Verkaufspreise der Wettbewerber. Die hier angewandten Methoden beginnen bei einfachen "gleitenden Durchschnitten" und reichen über die traditionelle Regressionsanalyse, modernen Verfahren wie Kausalanalysen und komplexen Zeitreihenanalysen (z.B. ARIMA- oder GARCH-Modelle) bis hin zu neuronalen Netzen oder der Fuzzy Logik. Die quantitativen Frühwarnsysteme sind den qualitativen bei kurz- bis mittelfristigen Prognosen normalerweise deutlich überlegen, haben jedoch ihre Schwächen beim Aufspüren von strukturellen Veränderungen, sogenannter Diskontinuitäten.

Frühwarnsysteme auf Basis traditioneller ökonometrischer Methoden – insbesondere also der Regressionsanalyse – werden entwickelt, indem man Daten aus der Vergangenheit auswertet und hieraus ein "Modell" der Realität ableitet. Ein solches Modell, welches mit historischen Daten entwickelt wurde, dient dann bei der Verarbeitung jüngerer Informationen (zu Prognosezwecken) dazu, Aussagen über die Zukunft abzuleiten.

In dem ersten Schritt, der Spezifikation des Modells⁵, wird eine i.d.R. verbal formulierte Theorie über die Zusammenhänge zwischen den erklärenden Variablen und der Zielvariable auf ein formales (ökonometrisches) Modell abgebildet⁶. Diese Modellspezifikation umfasst die Auswahl und die exakte Operationalisierung der aufzunehmenden messbaren Variablen, die Festlegung der aus einer zu Grunde liegenden ökonomischen Theorie ableitbaren Zusammenhänge zwischen den Modellvariablen und oft auch die Spezifikation der funktionalen Form der Abhängigkeiten zwischen den Variablen. Nach der Modellspezifikation sind alle zu schätzenden Parameter bekannt. Diese Parameter sind dabei die im Untersuchungszeitraum als konstant angenommenen Charakteristika des untersuchten ökonomischen Systems und beschreiben damit die Gesamtstruktur des Prognosesystems.

Bei der anschließenden Parameterschätzung werden durch ein geeignetes ökonometrisches Schätzverfahren numerische Schätzer für die unbekannt, tatsächlichen Modellparameter bestimmt. Diese Schätzer sollten erwartungstreu, konsistent und effizient sein.

Ziel des anschließenden dritten Schrittes beim Aufbau eines Prognosesystems ist es, die Schätzergebnisse zu überprüfen. Dazu wird zunächst getestet, ob die Voraussetzungen für den Einsatz des gewählten Schätzverfahrens erfüllt waren⁷. Nur wenn die jeweiligen Vor-

⁴ Vgl. zur Psychologie unternehmerischer Entscheidungen: *Gleißner*, Faustregeln für Unternehmer, Wiesbaden 2000 (insbesondere Kapitel 4).

⁵ Vgl. *Hujer/Cremer*, Empirische Wirtschaftsforschung, München 1978 S. 183 - 195 und S. 249 - 272.

⁶ Zu beachten ist, dass die Ergebnisse jeder empirischen Schätzungen wesentlich von den bei der Modellspezifikation verwendeten (a priori) Annahmen (Priors) abhängig.

⁷ Der häufig angewendeten Kleinste-Quadrate-Schätzung (OLS) liegen z.B. die folgenden Annahmen zugrunde:

1. lineare Unabhängigkeit der erklärenden Variablen X_i
2. Residuen μ und erklärende Variablen X_i sind unabhängig

aussetzungen erfüllt sind, kann man sicher sein, Schätzer zu erhalten, die den oben aufgezählten Anforderungen entsprechen. Zeigen statistische Tests, z.B. der Dubin-Watson-Test auf Autokorrelation der Residuen, signifikante Verletzungen der Annahmen, so ist es erforderlich, ein anderes, möglichst robusteres Schätzverfahren zu wählen⁸.

Ergänzt werden diese Tests durch Signifikanztests der geschätzten Parameter (t-Test) und die Berechnung von Gütemaßen für die Schätzgleichungen (z.B. durch Bestimmtheitsmaße), um zu prüfen, inwieweit das geschätzte Modell die empirischen Daten der Vergangenheit erklären kann. Schließlich werden die ökonomische Plausibilität sowie die Erklärungs- und Prognosegüte des Modells zusammenfassend bewertet. Als Gütekriterium für die Beurteilung eines so entwickelten Frühwarnsystems wird in der Praxis die Vorhersagequalität bezüglich neuer Daten angesehen, die auf verschiedenste Art und Weise gemessen werden kann. Als beliebte Größe zur Beurteilung der Qualität eines Prognose- bzw. Frühwarnsystems wird heute, neben einer Reihe weiterer Methoden, die Schätzung des Alpha- bzw. Beta-Fehlers anerkannt.

Eine unbefriedigende Prognosequalität von Frühwarnsystemen ist oft auf die mangelhaften methodischen Fähigkeiten der Anwender zurückzuführen, mit statistischen Problemen wie Heteroskedastizität⁹, Autokorrelation¹⁰ oder nicht-stationären Zeitreihen¹¹ umzugehen. Häufig werden zudem lediglich relativ einfache Verfahren genutzt, welche nur Informationen verwenden, die in den vergangenen Realisationen der zu prognostizierenden Variable enthalten sind ("gleitende Durchschnitte", "exponentielles Glätten"); kausale Abhängigkeiten von anderen Variablen werden vernachlässigt.

Besonders problematisch ist, dass sehr viele ökonomische Zeitreihen nicht-stationär sind. Sie haben also beispielsweise ein saisonales Verhalten, einen stochastischen Trend (integrierte Zeitreihen) oder einen deterministischen Trend, was einen sich zeitlich ändernden Mittelwert der Realisationen oder der Varianz der Zeitreihe zur Folge hat.

Da die meisten statistischen Verfahren Stationarität der betrachteten Variablen voraussetzen, sind sie bei nicht-stationären Zeitreihen nicht anwendbar. Wie man leicht zeigen kann, werden z.B. zwei Variablen, die jeweils einem deterministischen, linearen zeitlichen Trend folgen, grundsätzlich eine statistisch signifikante Korrelation aufweisen. Auch zwei unabhängige integrierte Zeitreihen¹² werden in der Regel eine signifikante Beziehung ("spurious regressions") aufweisen, wie z.B. Untersuchungen von Granger/Newbold¹³ und Plosser/Schwert¹⁴ gezeigt haben. Das Bestimmtheitsmaß wird im Mittel bei etwa 0,44 liegen (Nelson/Kang). Stochastische Trends in ökonomischen Zeitreihen wurden in empirischen Untersuchungen häufig festgestellt, was die Aussagefähigkeit von Frühwarnsystemen auf Basis einfacher Regressions- oder Zeitreihenanalysen sehr zweifelhaft erscheinen lässt.

Abbildung 2 zeigt als Beispiel für diese Probleme beim Aufbau von Frühwarnsystemen drei Zeitreihen, A, B und C. Dem Anschein nach besteht ein starker Zusammenhang zwischen den Zeitreihen B und C. Traditionelle statistische Verfahren, wie die Korrelation- oder Regres-

3. keine Autokorrelation der Residuen sowie

4. gleichbleibende Varianz der Residuen u (d. h. keine Heteroskedastizität).

⁸ "Ein Schätz- oder Testverfahren heißt **robust**, wenn es **bei Modellabweichungen** weiterhin im Kern **zuverlässig** arbeitet." (Eckey/Kosfeld/Dreger, Ökonometrie, Wiesbaden 1995 S. 222).

⁹ Bei Heteroskedastizität bleibt die Varianz der Residuen einer geschätzten Zeitreihe nicht konstant.

¹⁰ Bei Autokorrelation besteht eine Korrelation zwischen den Residuen einer geschätzten Zeitreihe zu unterschiedlichen Zeitpunkten.

¹¹ Nicht-Stationarität drückt sich häufig durch zeitabhängige Mittelwerte, also insbesondere trendartiges Verhalten, aus.

¹² Bei integrierten Zeitreihen basiert die Nicht-Stationarität auf einem sogenannten „stochastischen Trend“, der sich durch die Akkumulation zufälliger Störungen im Zeitverlauf ergibt (z.B. bei einem „Random Walk“) und zu Autokorrelationen nahe bei Eins führt.

¹³ Vgl. Granger/Newbold, Journal of Econometrics, 1974.

¹⁴ Vgl. Plosser/Schwert, Journal of Econometrics, 1997 S. 199 - 224.

sionsanalyse, würden einen entsprechenden signifikanten statistischen Zusammenhang zwischen B und C aufweisen (Korrelation = 0,92). Will man versuchen im Rahmen eines Frühwarnsystems den ermittelten statistischen Zusammenhang zwischen diesen beiden Zeitreihen für Prognosen auszunutzen, so ist jedoch mit keinen zuverlässigen Prognoseergebnissen zu rechnen. Ursache hierfür ist, dass die Korrelation der Zeitreihen B und C letztendlich zufallsbedingt ist, weil beide Zeitreihen einem Trend folgen. Man erkennt dies, wenn man die Differenzen der Zeitreihen¹⁵ (auch bspw. der Wachstumsraten) betrachtet. In Abbildung 3 ist erkennbar, wie die Veränderungen der Wachstumsraten B und C - D(B) und D(C) - in Zusammenhang stehen. Man erkennt, dass diese beiden Zeitreihen nur eine sehr schwache Korrelation aufweisen. Dagegen besteht eine sehr enge Korrelation zwischen den Differenzen der Zeitreihen A und C. Obwohl dies auf den ersten Blick gar nicht zu erwarten war, hat dies die Konsequenz, dass letztendlich die Entwicklung der Zeitreihen A und C kausal in engem Zusammenhang steht.

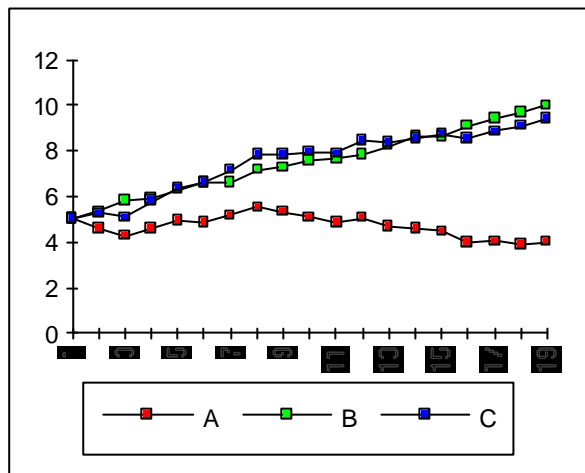


Abb. 2: Drei nicht-stationäre Zeitreihen

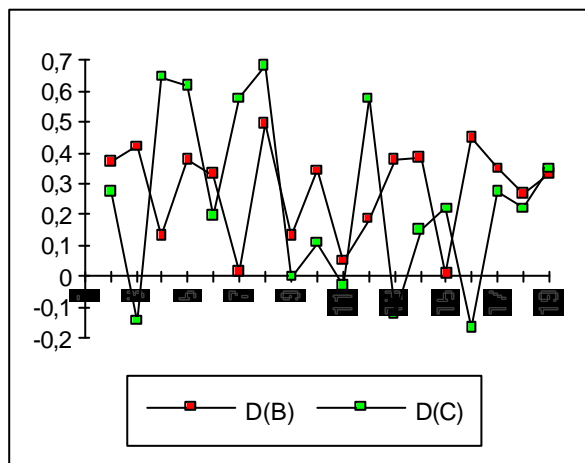


Abb. 3: Die Differenzen der Zeitreihen B und C zeigen keine Korrelation

¹⁵ $D(B)_t$ ist die Veränderung der Zeitreihe gegenüber dem eigenen Vorperiodenwert, also $D(B)_t = B_t - B_{t-1}$.

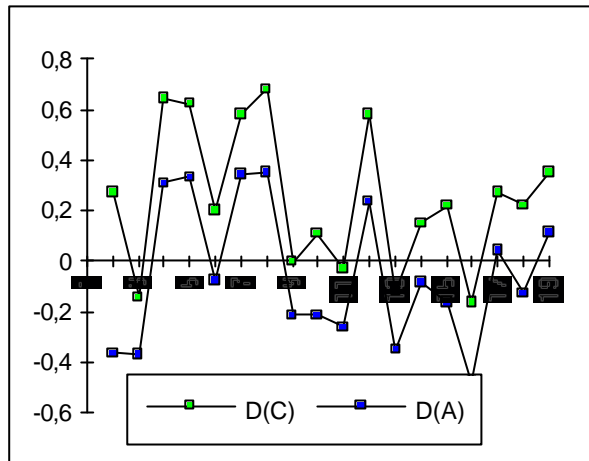


Abb.: 4: Die Differenzen der Zeitreihen A und C sind hoch-korreliert

Man kann zusammenfassend festhalten, dass die Anwendung üblicher Inferenzmethoden auf nicht-(mittelwert-)stationäre Variablen keine zuverlässigen Schlüsse über die tatsächlichen Zusammenhänge zwischen diesen Variablen zulässt. Die „üblichen“ Prognoseverfahren (gleitende Durchschnitte, exponentielles Glätten, „übliche“ Regression mit Niveaudaten) liefern unbefriedigende Ergebnisse¹⁶.

In den nachfolgenden Abschnitten 2.3 und 2.4 werden mit den neuronalen Netzen und den Kausalanalysen zwei relativ neue Methoden vorgestellt, die gegenüber den „üblichen“ Prognoseverfahren wesentliche Vorteile aufweisen, und so die Grundlage für neue, leistungsfähigere Frühwarnsysteme legen.

2.3 Neuronale Netze

Im Gegensatz zu vielen klassischen Verfahren eröffnen neuronale Netzwerke¹⁷ (gleichbedeutend: Künstliches neuronales Netz (KNN) oder Artificial Neural Network (ANN)) neue Möglichkeiten der Zeitreihenanalyse durch ihre Fähigkeit viele Eingangsgrößen zu verarbeiten und (ohne explizite Modellannahme) nicht-linear zu klassifizieren, wenngleich für sie auch viele der oben genannten Einschränkungen gelten. Im Gegensatz zu Regressionsanalysen sind aber die Voraussetzungen für den Einsatz neuronaler Netzwerke weniger restriktiv, ein Aspekt, der nachfolgend noch eingehender diskutiert werden soll. Als Haupteinsatzgebiete neuronaler Netzwerke gelten heute die Fragen der Klassifikation und Prognose, die eng miteinander verknüpft sind, da die Prognose eines beliebigen Sachverhalts, z.B. die Vorhersage, ob der Umsatz steigt oder nicht, auch als Klassifikationsproblem beschrieben werden kann. Die meisten Anwendungen neuronaler Netzwerke lassen sich heute unter den beiden o.g. Punkten subsumieren.

In den letzten Jahren, insbesondere seit 1985 durch die Entwicklung und Verbreitung des Error-Backpropagation-Algorithmus von D. Rumelhart und G. Hinton, haben die neuronalen Netzwerke einen breiten Einzug in die verschiedenen Sparten der Industrie, insbesondere aber in Banken und Versicherungen, gehalten. Vermehrt finden Sie sich als Substitut in Prognosemodellen und ersetzen bzw. erweitern klassische Anwendungen, die z.B. auf Regressionsanalysen basieren oder diskriminanzanalytischer Natur sind.

¹⁶ Da nicht-stationäre, stochastische Zeitreihen ein langfristig nicht prognostizierbares Verhalten zeigen, ist es naheliegend, dass sich ihre Niveaus im allgemeinen beliebig weit (und nicht prognostizierbar) auseinander entwickeln können. Dies trifft jedoch bei kointegrierten Zeitreihen nicht zu. Das charakteristische an kointegrierten Zeitreihen ist, dass individuell nicht-stationäre Zeitreihen langfristig einen Zusammenhang zeigen. Eine bestimmte Linearkombination dieser Zeitreihen ist stationär bzw. weist zumindest einen niedrigeren Integrationsgrad auf. Es besteht somit eine Art langfristige „Gleichgewichtsbeziehung“ zwischen den Variablen, was für den Aufbau von Prognosesystemen ausgenutzt werden kann.

¹⁷ Vgl. Füsser, Neuronale Netze in der Finanzwirtschaft, Wiesbaden 1995.

2.3.1 Aufbau und Funktionsweise neuronaler Netzwerke

Neuronale Netze erheben den Anspruch, die Denkprozesse des Menschen abzubilden. Sie sollen, so ist es der Wunsch einiger Wissenschaftler, menschliches Entscheidungsverhalten nachbilden. Sitz der intelligenten Leistungen des Menschen ist sein Gehirn, bestehend aus sogenanntem Nervenzellengewebe, welches beim Menschen auf einem Quadratmillimeter ca. 100.000 eng miteinander verknüpfte Nervenzellen, sogenannte Neuronen, besitzt. Sie stellen im biologischen Vorbild künstlicher neuronaler Netzwerke die aktiven "Recheneinheiten" dar, von denen sich ca. 100 Milliarden im menschlichen Gehirn finden. Man weiß heute, dass ein einzelnes Neuron mit 1.000 bis 10.000 anderen Neuronen verbunden ist. Dies bedeutet, dass das menschliche Gehirn in seiner Struktur hochgradig parallel und komplex aufgebaut ist, wodurch seine Leistung und Schnelligkeit begründet werden.

Künstliche neuronale Netzwerke sind im Vergleich zu ihrem biologischen Vorbild vergleichsweise bescheiden. Sie bestehen i.d.R. aus wenigen Hundert miteinander vermaschten Neuronen. Jedes Neuron ist dabei innerhalb eines KNN ein gar nicht so simpler "Prozessor", der ankommende Signale (Eingangsgroßen) verarbeitet und daraus Ausgaben erzeugt, die über seine Kommunikationsschnittstellen an viele andere Zellen weitergeleitet werden.

Besondere Bedeutung wird bei neuronalen Netzwerken dem Lernen beigemessen. Lernen (anhand von historischen Beispieldaten) findet statt, indem sogenannte synaptische Übertragungsfaktoren, die die Eingangsinformationen eines Neurons gewichten, angepasst werden. Die aus einem Lernvorgang hervorgehenden Ausprägungen der synaptischen Gewichtungsfaktoren der Neuronen, die auf Eingangsgroßen wirken und Ergebnisgroßen determinieren, stellen die eigentliche Wissensbasis sowohl beim biologischen Vorbild als auch innerhalb eines künstlichen neuronalen Netzwerkes dar. Durch ihre Fähigkeit, die Struktur in gegebenen Daten selbständig herauszudestillieren, sind neuronale Netze auch Expertensystemen überlegen, die sich grundsätzlich auch als Prognosesystem eignen würden. Bei der Eingabe der gesammelten Daten der Vergangenheit zur Erstellung eines "Neuro-Modells" muss nämlich grundsätzlich weniger Problemverständnis vorhanden sein als beim Experten, der aufgrund seiner Wissensbasis zusammen mit einem Computerfachmann ein Regelsystem konstruiert. Und Experten widersprechen sich häufig, eben weil der Mensch ökonomische Zusammenhänge mit ihrer Vielzahl an sich überlagernden, in ihrer Tendenz oftmals gegenläufigen Variablen, manchmal nur sehr schwer überblickt.

Das Entscheidungsverhalten eines neuronalen Netzwerkes hängt gleichermaßen von den im Rahmen des Wissenserwerbs gewonnenen Gewichten, den Synapsen, dem Lernmechanismus zur Anpassung der Synapsengewichte als auch deren spezifischer Verarbeitungsform ab, deren Alternativen an dieser Stelle nicht im Detail diskutiert werden können. Die Funktionalität eines neuronalen Netzwerkes basiert folglich auf der Formulierung von Verarbeitungs- und Lernmechanismen für künstliche Neuronen, wobei deren geeigneter Zusammenschluss ein neuronales Netzwerk ausmacht.

Ein neuronales Netzwerk besteht insgesamt aus drei Komponenten, nämlich

- den elementaren Recheneinheiten, den sogenannten künstlichen Neuronen,
- der Topologie des Netzes, also der Beschreibung seiner inneren Vernetzung und
- den Lernregeln, die die Veränderung der Kopplungsstärken bzw. der Kommunikationsintensität der Synapsen zwischen den Neuronen bestimmen.

Die Grundidee beim Aufbau neuronaler Netzwerke ist es somit, die Strukturen des menschlichen Gehirns und dessen Funktionsweise nachzubilden, z.B. zu Vorhersage- und Prognosezwecken.

2.3.2 Anwendungsvoraussetzungen für neuronale Netzwerke

Das besondere Interesse an den neuronalen Netzwerken liegt u.a. darin begründet, dass mit ihnen ein Werkzeug zur Verfügung gestellt wird, das es ermöglicht, Aufgabenstellungen zu bearbeiten, deren Lösung mit traditionellen Methoden bisher undenkbar war. Die Untersuchung komplexer Fragestellungen, zu denen der Aufbau von Frühwarn- und Prognosesystemen zählt, kann in vielen Fällen nicht algorithmen- bzw. regelbasiert erfolgen, weil bei vielen Problemstellungen, die der Mensch bearbeitet, keine scharfe algorithmische Formulierung möglich ist. In solchen Fällen versucht man heute mit neuronalen Netzwerken (und/oder der Fuzzy Logik) alternative Wege vorzuzeichnen. Neuronale Netze eröffnen hierbei völlig neue, bisher ungeahnte Perspektiven, da die Systeme nicht mehr programmiert oder modelliert sondern trainiert werden. Die eigentliche Modellbildung erfolgt somit autonom mittels eines Trainings- bzw. Lernverfahrens.

Generalisierbarkeit, Fehlertoleranz und in Kopplung mit der Fuzzy Logik die unscharfe Informationsverarbeitung sind dabei die dominant charakterisierenden Eigenschaften neuronaler Netze.

Anwendungsfelder von neuronalen Netzwerken sind dadurch gekennzeichnet, dass kein beschreibbares Wissen zur Problemlösung existiert. Dies ist das wesentliche Abgrenzungsmerkmal auch zu den bisher diskutierten Verfahren bzw. Vorgehensweisen. Konventionelle Modelle basieren oftmals auf einer formalen algorithmisierten Problembeschreibung. Schwächen besitzen sie, wenn Problemstellungen nicht oder nur mit hohem Arbeitsaufwand ausformuliert werden können. Diese treten i.d.R. dann zutage, wenn vage, unvollständige oder widersprüchliche Informationen die Entscheidungsfindung tangieren. In diesem Zusammenhang wird oftmals der "Knowledge Acquisition Bottleneck" erwähnt.

Typische Vertreter der Klasse der neuronalen Netzwerke, wir können diese hier nicht im Detail diskutieren, besitzen weitgefaste Einsatzmöglichkeiten. Ihre Einsatzgebiete umfassen die Bereiche der nicht-linearen Diskriminanz-, Regressions- und Zeitreihenanalyse. Sie sind in der Lage, hochdimensionierte Regionen eines Eingaberaums zu separieren.

Neben den bekannten statistischen Methoden der Regressions- und Zeitreihenanalyse besitzt heute das Backpropagation-Verfahren das breiteste Einsatzspektrum. Neuronale Netze schließen durch ihre Anwendungsbereiche Lücken, die klassische Methoden in der Vergangenheit offen ließen. Die bislang in der Praxis i.d.R. üblichen mathematischen Techniken konzentrieren sich auf zwei spezielle Typen von Strukturen: Entweder berücksichtigen sie sehr viele Variablen, lassen aber nur lineare Wechselwirkungen der Einflussgrößen zu. Oder sie erlauben ein komplexes Verhalten sehr weniger Variablen. Ökonomische Systeme sind jedoch von Natur aus Vielvariablensysteme, die nur beschränkt separierbar sind und deren nicht-lineare Dynamik immer nur in Überlagerung vieler Einflussfaktoren zu beobachten ist.

Noch hervorzuheben ist die inhärente Fähigkeit vieler Typen von neuronalen Netzwerken zur Validierung und Erklärbarkeit von Ergebnissen beizutragen, z.B. durch vielschichtige Möglichkeiten zur Durchführung von Sensitivitätsanalysen. Vielerorts wurden in der Vergangenheit Techniken zur Offenlegung des Modellverhaltens entwickelt, die den früher oftmals gehörten Vorwurf der "Black-box"-Verarbeitung heute entkräften. Forschungsschwerpunkte sind dagegen noch die Verfahren zur Netzwerkoptimierung, der Datenauswahl und der Selektion geeigneter Netzwerkstrukturen. Auch hier zeichnen sich jedoch Lösungen ab. Im Forschungsmittelpunkt steht dabei zur Zeit die Entwicklung streng deterministischer Vorgehensweisen zur automatisierten Netzgestaltung bzw. -optimierung.

Neuronale Netzwerke eignen sich somit bestens für Problemstellungen, die ständigem Wandel unterliegen und ein "learning by example" ermöglichen.

2.3.3 Neuronale Netzwerke in Frühwarn- und Prognosesystemen

Die bedeutendsten Einsatzspektren neuronaler Netzwerke finden sich heute noch, wenn man über Frühwarn- und Prognosesysteme spricht, sicherlich in der Finanzwirtschaft. Erst wenige Veröffentlichungen diskutieren ihre Möglichkeiten im Feld der Unternehmensplanung bzw. im Risikomanagement, wenngleich sie wohl auch hierfür ein methodisch abgesichertes Werkzeug zur entscheidungsunterstützenden Information von Führungskräften sind, so die Resultate erster Publikationen. Bei manchen unkritischen "Lobgesängen" auf die Überlegenheit von KNN sollte man jedoch sehr genau darauf achten, ob es sich um eine wissenschaftliche Arbeit oder mehr um ein Verkaufsprospekt handelt.

Ein Grund für den Enthusiasmus zur Verwendung von neuronalen Netzwerken bei Voraussagen ist deren Fähigkeit, sehr komplexe inhärente Gleichungen eines Systems zu modellieren. So forderte zum Beispiel ein Finanzberater einen skeptischen Kollegen heraus und bat ihn um irgendeine mathematische Gleichung. Der Kollege wählte: $a^2 + b^2 + c = r$. Ein kleines neuronales Netzwerk wurde gebaut und mit verschiedenen Werten für a , b , c und r trainiert. Nach der Trainingsphase konnten dem Netzwerk beliebige Werte für a , b und c eingegeben werden und das neuronale Netzwerk (approximierte) jedesmal das richtige Resultat für r . Diese Fähigkeit, Gleichungen von schlecht, unscharf oder gar nicht zu definierenden Prozessen zu simulieren, macht neuronale Netzwerke für eine große Anzahl von Voraussage-Experten zu einem sehr attraktiven Hilfsmittel.

Klassische neuronale Prognoseanwendungen finden sich heute, wie erwähnt, in der Finanzwirtschaft, zu denen z.B. die Bereiche der Vorhersage von Aktienkurs-, Währungs- oder Zinsentwicklungen zählen. In der Praxis finden sich heute eine Reihe von Modellen mit unterschiedlichen Lösungswegen und Ergebnissen im Einsatz. Die mit Hilfe neuronaler Netze realisierten Prognoseanwendungen zeigen, dass durch dieses Instrument eine Fülle von alternativen Vorgehensweisen eröffnet wird, die im wesentlichen durch die Selektion von einzelnen Modellparametern, -variablen, -einflussfaktoren und -typen voneinander abgegrenzt werden können. Der Vorteil von neuronalen Netzwerken, der sich jedoch schnell auch in einen Nachteil umkehren kann, wird von vielen darin gesehen, dass ein Modellierungsprozess umgehend mit ihnen begonnen werden kann, ohne eine strikte ökonomische Theorie formuliert zu haben. Man benötigt bei neuronalen Netzen lediglich eine "Modellvorstellung" über das Spektrum der relevanten Variablen (Eingangs- und Ausgangsgrößen). Neuronale Netze sind in der Lage, diese Modellvorstellung in ein Prognosemodell zu transferieren, welches ein vereinfachtes Abbild der Wirklichkeit darstellt. Somit bildet sich das eigentliche Modell erst im Laufe der Anwendung der Methodik, d.h. während des Trainings, aus den Daten heraus. "Modellvorstellung" im neuronalen Sinn bedeutet folglich im wesentlichen die Festlegung auf eine möglichst repräsentative Teilmenge an Variablen (hier i.S. von Eingangsgrößen), die die Zielgrößen determinieren und deren möglichst effiziente Aufbereitung. Aus unserer Sicht gilt jedoch auch für neuronale Netzwerke: "Es existiert nichts praktikableres als eine gute Theorie".

Gerade bei der Prognose innerhalb der Unternehmensplanung oder im Risikomanagement gilt es das "Wissen um beobachtbare zyklische Regelmäßigkeiten" oder das "Wissen um Gesetze" sich allgemein zu nutze zu machen. Grundsätzlich gibt es jedoch beim Aufbau neuronaler Netze für die Zusammenstellung der Modellvariablen keine inhaltlichen Vorgaben bzw. methodischen Restriktionen. Oftmals ist es ja auch gar nicht möglich, korrekt anzugeben, welche Faktoren den Prognosegegenstand beeinflussen. Fragt man Experten, dann können diese durchaus polarisierende Meinungen haben. Die kausallogische Verknüpfung der Eingabe- und Ausgabegrößen eines neuronalen Netzwerkes, sollte jedoch, wie bei allen hier angesprochenen Verfahren ebenso, plausibel sein und längerfristige Gültigkeit besitzen. Der zu lernende Strukturzusammenhang zwischen Ein- und Ausgabe muss deshalb schon über einen dem Problem angemessenen Zeitraum als signifikant angesehen werden können. Kritischer Punkt ist die dabei unterstellte Strukturinvarianz: In der Vergangenheit aufgefundene Zusammenhänge haben auch in der Zukunft Gültigkeit. Eine vollständige Invarianz kann es jedoch aufgrund der Dynamik der Einflussgrößen nicht geben. Um diese Invarianzhypothese nicht in ihrer krassesten Form zu unterstellen, wird innerhalb der neuronalen Analyse ebenso

nach Strukturen gesucht, die über einen gewissen Zeitraum hinweg relativ stabil gewesen sind. Dies führt zu dem Dilemma, zwischen der Anzahl der Trainingsdaten und deren Aktualität bzw. Zusammenstellung abwägen zu müssen. Dies gab den Experten, die sich mit neuronalen Netzwerken auseinandersetzten, den Ruf von Experimentalwissenschaftlern. Eng geknüpft an die Zusammenstellung der Einflussfaktoren ist die Wahl des Netzwerktyps und der damit verbundenen Parameter. Aufgrund der kombinatorischen Vielfalt ist es jedoch auszuschließen, dass alle Kombinationen an Dateninput, Architekturen, Topologien und Parameterbelegungen betrachtet werden können.

Wie wir aufgrund früherer Forschungsaktivitäten wissen, scheint es, dass ökonomische Daten oft keine einfachen AR(I)MA-Prozesse, nicht beschreibbar durch simple lineare Modelle, kein weißes Rauschen und auch keine Random Walks sind. Falls es somit einen nachvollziehbaren Mechanismus zur Prognose eines Sachverhalts gibt, so ist ein neuronales Netz ein nützliches Hilfsmittel, um schnell und bequem mit Hilfe eines einfachen Algorithmus eine statistische Analyse vorliegender Daten vorzunehmen.

2.4 Kausalanalytische Methoden als Basis alternativer innovativer Frühwarnsysteme

Frühwarnsysteme sollten idealerweise nicht nur zukünftige Entwicklungen vorhersagen, sondern, wie gesagt, auch durch Bezugnahme auf die zugrundeliegenden Ursache-Wirkungs-Beziehungen erklären können, was möglichst weitgehende Strukturinvarianz voraussetzt. Es interessiert den Anwender sicherlich, welche anderen Variablen (Ursachen) eine bestimmte, interessierende Variable (Wirkung, Zielvariable) – z.B. den Umsatz – beeinflussen¹⁸. Gesucht wird also die kausale Abhängigkeitsstruktur¹⁹ (Wirkungszusammenhang) zwischen ökonomischen Variablen. Ein großer Vorteil solcher Frühwarnsysteme auf kausalanalytischer Grundlage besteht darin, dass nicht nur die zukünftige Entwicklung vorhergesagt, sondern auch erklärt wird, was zu einem wesentlich höheren Maß an Transparenz und Überprüfbarkeit führt.

Eine zentrale Schwierigkeit bei allen Versuchen, solche Abhängigkeitsstrukturen zwischen Variablen empirisch zu ermitteln, ist das "Kausalitätsproblem" (vgl. Holland, 1986). Das Kausalitätsproblem besteht darin, dass aus einer empirisch feststellbaren Korrelation (bzw. Kovarianz) zwischen Variablen – ohne weitere Informationen – nicht eindeutig auf die kausale Abhängigkeitsstruktur zwischen diesen Variablen geschlossen werden kann. Dies gilt selbst dann noch, wenn man von einer zufälligen Korrelation (spurious-regressions-Problem bei integrierten Zeitreihen) absieht. Die Korrelation zwischen zwei Variablen A und B kann nämlich auf unterschiedliche kausale Strukturen zurückgeführt werden, wie folgende Beispiele zeigen:

¹⁸ Außer eigentlichen Ursachen können prinzipiell auch Indikatoren zur Anwendung kommen, die zwar selbst keine Wirkung auf die Zielgröße haben, aber auf das Wirksamwerden der Ursache, die selbst möglicherweise nicht beobachtbar ist, hinweisen.

¹⁹ Kausalität wird definiert als "Vorhersagbarkeit auf Grundlage von Gesetzen". Kausalität darf in der realen Welt nicht deterministisch verstanden werden. Dies gilt gerade auch in den Wirtschafts- und Sozialwissenschaften. Der auf den Philosophen David Hume zurückzuführende Kausalitätsbegriff in den empirischen Wirtschafts- und Sozialwissenschaften basiert auf "Durchschnittswirkungen", die aus einer großen Anzahl von einzelnen Beobachtungen mit statistischen Methoden ermittelt werden. Der Kausalitätsbegriff wird somit nur in einem stochastischen Sinn verwendet werden ("stochastische Gesetze"). Kausale Aussagen haben damit z.B. folgende Struktur: "Falls Ereignis A gegeben ist, verändert sich die Wahrscheinlichkeit für das Eintreten des Ereignisses B".

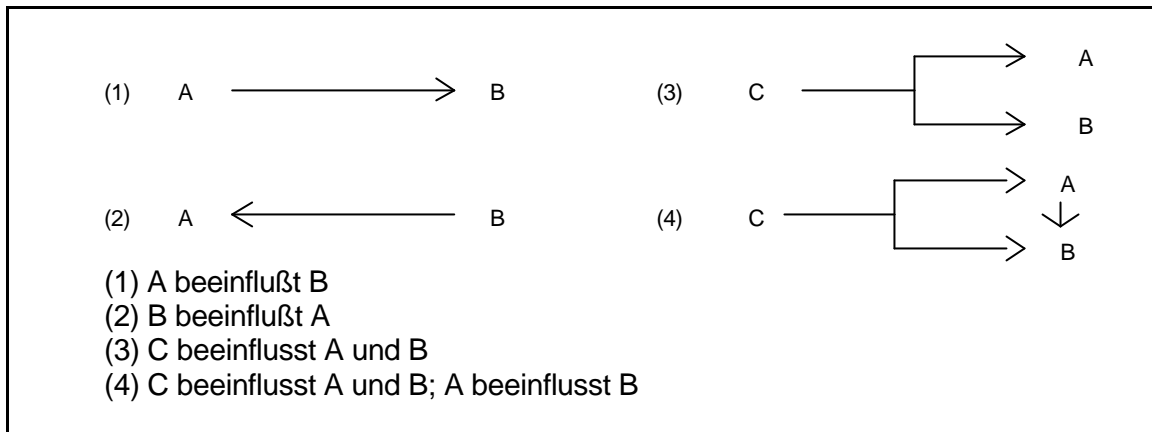


Abb. 5: Alternative Kausalstrukturen als Ursache einer Korrelation

Bei Fall (3) besteht zwischen den Variablen A und B eine Korrelation, die nicht auf einen kausalen Zusammenhang zwischen ihnen zurückzuführen ist. Man spricht hier von "Scheinkorrelation". Bei Fall (4) ist die empirische Korrelation nur teilweise kausal zu interpretieren.

Wesentlich ist somit, dass eine empirisch festgestellte Korrelation zwischen zwei Variablen nicht grundsätzlich als Wirkungszusammenhang zwischen diesen verstanden werden darf. Man kann somit zusammenfassend drei prinzipielle Arten von Korrelation zwischen zwei Variablen A und B unterscheiden:

1. zufällige Korrelation (z.B. falls A und B nicht-stationäre Zeitreihen sind)
2. Scheinkorrelation (wenn eine Drittvariable A und B beeinflusst)
3. kausalbedingte Korrelation (Ursache-Wirkungs-Beziehung zwischen A und B)

Das Kausalstrukturmodell stellt die kausale Abhängigkeit zwischen allen betrachteten Variablen eines Systems – z.B. als Pfaddiagramm – dar.

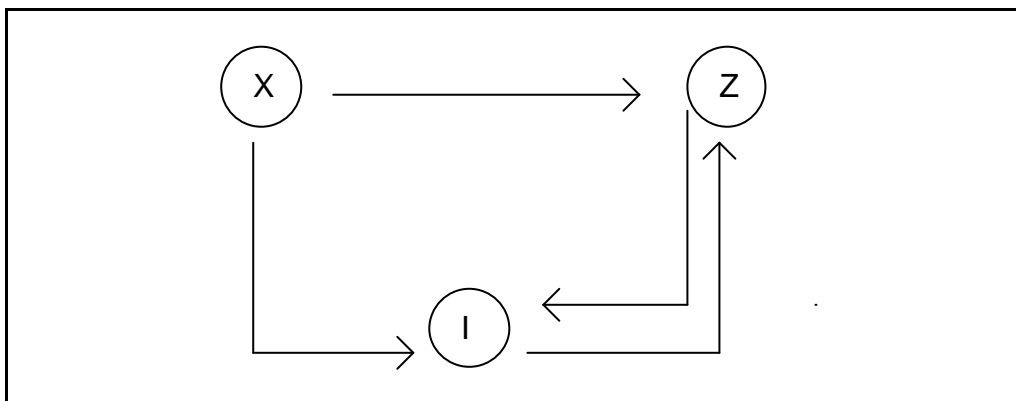


Abb. 6: Kausalstrukturmodell des "Wirkungsdreiecks" aus Abb. 1

Programmtechnisch lässt sich das Kausalstrukturmodell z.B. mit LISREL, einem Zusatzmodul des Statistikprogrammpakets SPSS, realisieren. Die Schätzung der Parameter ist nur mit Hilfe von Systemschätzverfahren möglich, bei denen – im Gegensatz zur "üblichen" Regressionschätzung – alle Modellgleichungen simultan geschätzt werden.

Die Grundidee solcher – zu neuronalen Netzen alternativer – Prognosesysteme besteht darin, Wirkungszusammenhänge zwischen interessierenden Variablen nur zwischen den von der univariaten zeitlichen Dynamik bereinigten Zeitreiheninnovationen (im einfachsten Fall

Wachstumsraten statt Niveauvariablen) zu untersuchen.²⁰ Gerade diese nicht schon aus der eigenen Vergangenheit prognostizierbaren Variablenkomponenten müssen nämlich durch die Wirkung anderer Variablen erklärt werden.

In der ersten Phase werden deshalb die univariaten Charakteristika der betrachteten Zeitreihen – also der Einfluss des Faktors Zeit – analysiert und für die weitere Untersuchung eliminiert. Dazu werden die Zeitreihen – so weit nötig – zunächst durch Differenzenbildung in stationäre Zeitreihen umgewandelt, die dann mittels ARMA-Modellen beschrieben werden können. Bei ARMA-Modellen wird zunächst darauf verzichtet, die Variablen zu bestimmen, die eine zu erklärende Variable Y beeinflussen. Statt dessen wird Y als gewichtetes Mittel seiner eigenen Vergangenheitswerte und früherer stochastischer Schocks erklärt; es wird also das „typische Verhalten“ ermittelt. Die Residuen der jeweiligen ARMA-Modelle sind die Variablenkomponenten, die nicht unter Verwendung der vergangenen Realisationen dieser Variable vorhergesagt werden können. Sie haben „white-noise“-Eigenschaft und sind somit autokorrelationsfrei.

Vorteilhaft im Vergleich mit herkömmlichen ökonomischen Verfahren ist die Verwendung von Zeitreiheninnovationen insbesondere deshalb, weil ineffiziente oder verzerrte Parameterschätzungen infolge von Multikollinearität und fälschlicherweise signifikant geschätzte Korrelationsbeziehungen zwischen völlig unabhängigen Variablen infolge des Einflusses des Faktors Zeit (spurious-regressions-Problem) vermieden werden.

Ein weiterer ökonomischer Vorteil der Verwendung von Zeitreiheninnovationen ergibt sich auch hinsichtlich der Schätzung von Lag-Strukturen (d.h. verzögerte Wirkungen), weil im Gegensatz zu den üblichen Ansätzen die Variablen zu verschiedenen zeitlichen Lags unkorreliert sind. Multikollinearitätsprobleme treten somit auch bei Modellen mit verteilten Verzögerungen nicht auf.

Für den Aufbau eines solchen kausalanalytischen Frühwarnsystems ergibt sich der folgende Ablauf:

1. Hypothesenbildung

Frage: „Wovon könnte die zu prognostizierende Variable kausal abhängen?“

Antwort/Beispiel: „Der Umsatz ist abhängig von Auftragsbestand, Geschäftsklima, Zinsen, Verkaufspreisen und der Kundenzufriedenheit.“

2. Operationalisierung der Modellvariablen

Frage: „Welche konkreten Zeitreihen sollen verwendet werden?“

Antwort/Beispiel: „Wir betrachten Monatsdaten der oben genannten Variablen für den Zeitraum Januar 1990 bis Juni 1999.“

3. Spezifikation des Strukturmodells

Frage: „Welche Wirkungsbeziehungen bestehen?“

Antwort/Beispiel: „Außer den oben genannten direkten Wirkungen der verschiedenen Variablen auf den Umsatz wird angenommen, dass die Zinsen das Geschäftsklima beeinflussen und so auch indirekt auf den Umsatz wirken.“

4. Untersuchung der Variablen auf Trends sowie Integrationsgrad

Durch das Bilden von Differenzen werden alle langfristigen Komponenten (z.B. „Trends“) herausgefiltert und das Augenmerk kann auf die kurzfristigen, mittels stationären ARMA(p,q)-Ansatz besser prognostizierbaren Komponenten gelenkt werden. Ein unnötiges Überdifferenzieren hat relativ geringe Auswirkungen (Plosser/Schwert), weil die mit der

²⁰ Vgl. zur Methodik, *Gleißner*, Notwendigkeit, Charakteristika und Wirksamkeit einer heuristischen Geldpolitik, Stuttgart 1999 S. 330 - 349. Dort wird auch ein komplexes Anwendungsbeispiel, der Prognose und der kausalen Erklärung von Veränderungen der Geldmarktzinsen, erläutert

Kleinsten-Quadrate-Methode geschätzten Parameter konsistent und erwartungstreu bleiben.

5. Berechnung der Zeitreiheninnovationen (ARIMA-Modellierung)

Dem zeitreihenanalytischen Ansatz von Box/Jenkins²¹ folgend lässt sich eine Zufallsvariable als gewichtetes Mittel aus gegenwärtigen und q vergangenen stochastischen Schocks μ_t darstellen (sogenannte MA(q)-Darstellung). Alternativ ist eine Darstellung als autoregressiver Prozess der Ordnung p (AR(p)-prozess), also in Abhängigkeit früherer Werte ihrer selbst, möglich. Eine Kombination beider Ansätze sind ARMA(p,q)-Modelle, die beispielsweise so spezifiziert werden sollen, dass die Anzahl der zu schätzenden Parameter, also die Summe von p und q, minimal wird. Es gilt:

$$y_t = \alpha_1 y_{t-1} + \alpha_2 y_{t-2} + \dots + \alpha_p y_{t-p} + u_t + \beta_1 u_{t-1} + \beta_2 u_{t-2} + \dots + \beta_q u_{t-q}$$

6. Schätzung der Modellparameter

Bei der Kausalanalyse bzw. Kovarianzstrukturanalyse wird nun mit den in Schritt vier ermittelten Zeitreiheninnovationen (u_t) getestet, ob das unter 1. und 3. spezifizierte (hypothetische) System von Annahmen über die Kausalbeziehungen (= Strukturmodell) mit den empirisch festgestellten Korrelationen zwischen den Zeitreihen in Übereinstimmung zu bringen ist und damit die Grundlage für eine Prognose bietet.

7. Statistische Beurteilung der Parameterschätzung

Hierbei wird die Qualität des Gesamtprognosemodells und die Präzision der Schätzung einzelner Parameter durch geeignete Gütemaße bewertet.

8. Ökonomische Interpretation der Ergebnisse und Erstellung von Prognosen

In dieser letzten Phase kommt das Prognosesystem zur Anwendung; es werden Vorhersagen über die zukünftige Entwicklung der interessierenden Zielvariablen erstellt.

Im Abschnitt 3.3 wird beispielhaft ein Umsatzprognosesystem vorgestellt, das mit dieser Methodik entwickelt wurde.

3. Anwendung von Frühwarn- und Prognosesystemen

3.1 Anwendungsbeispiele neuronaler Netzwerke

Frühwarn- und Prognosesysteme finden sich heute in den bereits diskutierten Ausprägungen in verschiedensten Formen und Funktionen innerhalb eines Unternehmens, wobei, wie erwähnt, gemessen an der Anzahl der Publikationen bei Prognosesystemen wohl die Aktienkurs- und Zinsprognose an erster Stelle zu nennen wäre. In betrieblichen Frühwarn- oder Managementinformationssystemen finden sich heute nur vereinzelt neuronale Netzwerke, die sich prinzipiell jedoch für ein wesentlich breiteres Anwendungsfeld eignen würden. Ihre Nichtverbreitung liegt im wesentlichen heute wohl noch am Mangel ausgebildeter und erfahrener Netzwerkdesigner.

Neben den typischen Steigt-/Fällt-Prognosen innerhalb der Finanzwirtschaft finden sich heute neuronale Netzwerke z.B. im Bereich der Prognose von Absatzmengen(schwankungen), Entwicklung der Auftragslage, Renditen oder Wechselkursen. Ebenso werden sie genutzt, um Timing-Zeitpunkte zu determinieren oder den Geschäftsklima-Index des Ifo-Instituts für Wirtschaftsforschung zu prognostizieren.

²¹ Vgl. *Box/Jenkins, Time Series Analysis, Forecasting and Control*, San Fransisco, 1986.

Insgesamt kann die Entwicklung neuronaler Netzwerke für Prognose- oder Frühwarnzwecke im Spannungsfeld von drei Problemen gesehen werden: gewünschter Datenfit, ökonomische Plausibilität und Generalisierungsfähigkeit. Keinesfalls darf es jedoch im Rahmen der Entwicklung eines Ansatzes zu einem reinen "curve fitting" kommen. Die modellkonsistente Vorauswahl der Einflussgrößen ist sehr wichtig und sollte grundsätzlich nicht allein einem neuronalen Netzwerk überlassen werden.

3.2 Die Anwendung strategischer Frühwarnsysteme

Wichtigste Zielsetzung der Unternehmensstrategie ist es, "Erfolgspotenziale" aufzubauen und zu erhalten²². Ein Erfolgspotenzial ist die besondere Fähigkeit, mit der ein Unternehmen mittel- bis langfristig Gewinne erzielen kann und die damit zur Steigerung des Unternehmenswertes beiträgt. Diese Erfolgspotenziale können vom Kunden wahrnehmbare Wettbewerbsvorteile (z.B. guter Service oder eine bekannte Marke) oder besondere interne Stärken im Vergleich zu den Wettbewerbern (z.B. moderne Maschinen, effiziente Arbeitsprozesse) sein. Eine besondere Stellung unter den Erfolgspotenzialen haben langfristig wirksame Kernkompetenzen – z.B. besondere Fähigkeiten der Mitarbeiter – mit deren Hilfe zukünftig regelmäßig Wettbewerbsvorteile oder interne Stärken generiert werden können. Der Aufbau von Kernkompetenzen ist vermutlich die wichtigste Teilaufgabe der strategischen Unternehmensplanung.

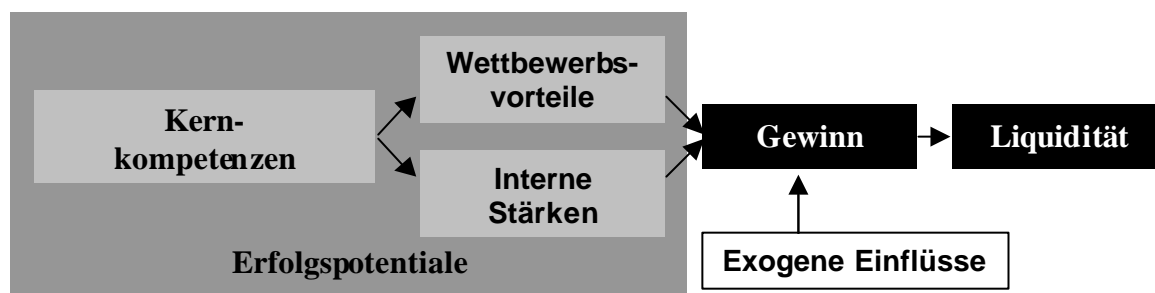


Abb. 7: Erfolgspotenziale

Genau wie der Erfolg eines Unternehmens mittels steigender Gewinne letztendlich eine notwendige (wenn auch nicht hinreichende) Bedingung für eine günstige Liquiditätsentwicklung ist, sind Erfolgspotenziale die Voraussetzung für zukünftige Gewinne.

Um sich gute Chancen für zukünftige Gewinne zu sichern, sollten die Erfolgspotenziale (Kernkompetenzen, interne Stärken und Wettbewerbsvorteile) als "Vorsteuergröße" zukünftiger Gewinne und Liquidität genauso gezielt gesteuert werden, wie alles, was heute Gewinne bringt (z.B. die Akquisition neuer Aufträge). Die Aufgaben der Strategischen Frühaufklärung sind dabei:

- Die Identifikation *exogener Einflüsse*, die langfristig die Gewinnerwartungen des Unternehmens mitbestimmen (z.B. neue technologische Entwicklungen, Änderungen der Wettbewerbsstruktur, Konsumtrends).
- Die Früherkennung möglicher interner *Veränderungen der Erfolgspotenziale*, also z.B. der sich abzeichnende Abbau einer Kernkompetenz, um eine mögliche "Strategische Krise" so früh erkennen zu können, dass noch keine Auswirkungen auf Rentabilität oder gar Liquidität eingetreten sind.

²² Vgl. *Gleißner*, Faustregeln für Unternehmer – Ein Expertensystem für strategische Kompetenz und Entscheidungsfindung, Wiesbaden 2000.

Ansoff²³ geht davon aus, dass im Prinzip kein Ereignis und insbesondere keine exogene Störung vollständig unvorhersehbar eintritt. Auch "Diskontinuitäten", also strukturelle Änderungen der wirtschaftlichen Rahmenbedingungen, haben damit Vorläufer, die für eine Vorhersage genutzt werden können. Je früher diese Vorläufer identifiziert werden können, desto größer ist die Chance rechtzeitig Gegenmaßnahmen einzuleiten. Das Problem ist allerdings, die Vorläufer überhaupt ausfindig zu machen, da sie zumeist aus schlecht strukturierten, unklaren Informationen bestehen, die keine eindeutigen Schlussfolgerungen zulassen, was manche Wissenschaftler an der praktischen Bedeutung "schwacher Signale" zweifeln lässt.

Die strategische Frühaufklärung hat in diesem Kontext eine zweifache Aufgabe, nämlich einerseits die Identifikation von heute gegebenen Kausalzusammenhängen in der Wirtschaft und zum anderen die Früherkennung struktureller Veränderungen, dabei insbesondere möglicher Veränderungen von Kausalstrukturen.

Zwei grundsätzliche, sich sinnvoll ergänzende Methoden der strategischen Frühaufklärung werden oft unterschieden: Erstens kann das Umfeld eines Unternehmens permanent "abgetastet" werden (Scanning). Hat man mittels *Scanning* ein "schwaches Signal" identifiziert, so werden weitere Informationen zu diesem Phänomen gesucht. Diese zweite Methode der regelmäßigen, gezielten Informationssuche bezeichnet man als *Monitoring*.

	Ungerichtete Suche	Gerichtete Suche	
Informal	Das Abtasten nach (schwachen) Signalen außerhalb der Domäne, ohne festen Themenbezug	Das Abtasten nach (schwachen) Signalen innerhalb der Domäne ohne festen Themenbezug	Scanning
Formal	Das Abtasten nach (schwachen) Signalen außerhalb der Domäne, mit einem speziellen Themenbezug	Das Abtasten nach (schwachen) Signalen innerhalb der Domäne mit einem speziellen Themenbezug	
	Die Beobachtung und vertiefende Suche nach Informationen außerhalb der Domäne mit speziellem Themenbezug eines bereits identifizierten Signals	Die Beobachtung und vertiefende Suche nach Informationen innerhalb der Domäne mit speziellem Themenbezug eines bereits identifizierten Signals	Monitoring

Abb. 8: Basisaktivitäten einer strategischen Frühaufklärung (Quelle: *Krystek/Müller-Stewens*, Stuttgart 1993 S. 177)

Eine strategische Frühaufklärung auf Basis schwacher Signale zeigt oft folgenden Ablauf:

1. Scanning des Unternehmensumfeldes zur Identifikation von "schwachen Signalen"
2. Qualitative Beurteilung der Relevanz und ggf. zusätzlich quantitative Bewertung der Tragweite möglicher Veränderungen für die Zielvariablen des Unternehmens
3. Ermittlung der Dringlichkeit für eine betriebliche Reaktion
4. Gezielte Beschaffung ergänzender Informationen ("Monitoring")
5. Erarbeitung der Konsequenzen für die Unternehmensstrategie

3.3 Fallbeispiel: Aufbau eines kausalanalytischen Umsatzprognosesystems

²³ Vgl. *Ansoff*, Zeitschrift für betriebswirtschaftliche Forschung, 1976 S. 129ff.

Das folgende Beispiel zeigt die kausale Abhängigkeitsstruktur in einem Frühwarnsystem, welches auf die Prognose der zukünftigen Umsatzentwicklung abzielt. Man erkennt in Abbildung 9, welche Einzelfaktoren den Umsatz bestimmen (vgl. zur Methodik Abschnitt 2.3) und kann so Prognosen erstellen, die einen Umsatzrückgang mit einem Jahr Vorlauf anzeigen. Der Umsatz ist hier konkret abhängig vom Geschäftsklima (IFOG), dem Auftragsbestand (AUFTRAG), den eigenen Verkaufspreisen (PREISE), indirekt von dem Geldmarktzins (DZGM), der Einfluß auf das Geschäftsklima hat, sowie von der in regelmäßigen Befragungen erhobenen Kundenzufriedenheit (KUNDZUF), die die – in der Abbildung nicht dargestellte – Kundentreue beeinflusst.

Wesentlich ist, dass bei diesem kausalanalytischen Modell die wechselseitige Abhängigkeit zwischen den Bestimmungsfaktoren des Umsatzes ebenfalls ermittelt werden. Nur so ist es möglich, die komplexen Zusammenhänge in einem Unternehmen und seinem Umfeld für eine gezielte Unternehmenssteuerung transparent zu machen. Letztendlich zeigt das Frühwarnsystem für die Umsatzentwicklung somit die "Geschäftslogik" an, d.h. die belegbaren Zusammenhänge, die für die Umsatzentwicklung maßgeblich sind. Mit einem solchen System ist es nicht nur möglich mit einem Vorlauf von bis zu einem Jahr die Umsatzentwicklung fundiert zu prognostizieren. Für die praktische Unternehmensführung sogar noch wichtiger ist, dass durch das Aufzeigen der kausalen Abhängigkeitsstruktur erkennbar wird, mit welchen Steuergrößen das Unternehmen die Umsatzentwicklung gezielt beeinflussen kann. Oft gibt es innerhalb des Unternehmens nur sehr grobe und unter Umständen widersprüchliche Vorstellungen über diejenigen Faktoren, die beispielsweise den Umsatz maßgeblich bestimmen. Der Aufbau eines Frühwarnsystem erlaubt hier zusätzlich kausale Zusammenhänge – also die Geschäftslogik – zu präzisieren und auch empirisch zu untermauern. Damit wird durch den Aufbau von Frühwarnsystemen in vielen Fällen auch eine wesentliche Vorarbeit für den Aufbau einer fundierten Balanced Scorecard als strategisches Steuerungsinstrument des Unternehmens gelegt.

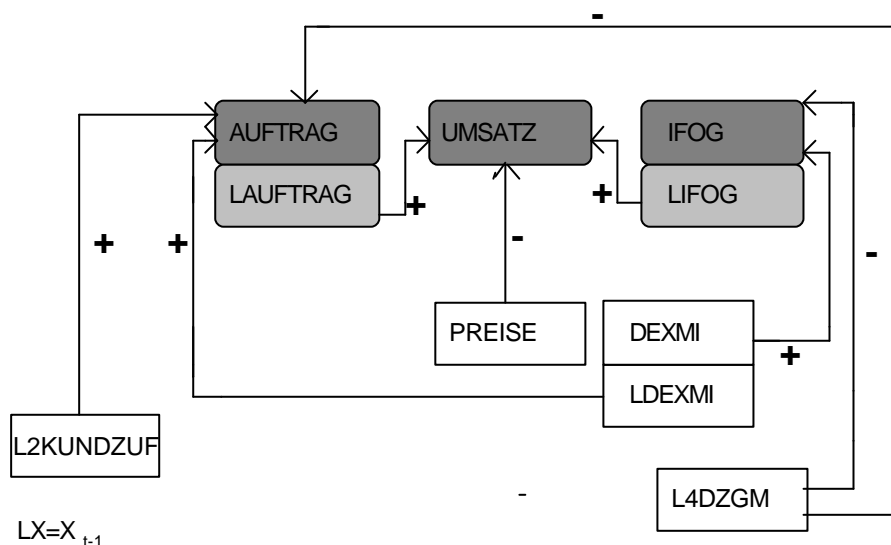


Abb. 9: Frühwarnsystem für die Umsatzentwicklung

Die möglichen unmittelbaren Kosteneinsparungen eines solchen Absatzmengenprognose-systems lassen sich wie folgt abschätzen: In einem Großhandelsunternehmen machen die Vorräte durchschnittlich ca. 10% der Jahresumsätze aus. Es wird (durchaus realistisch) angenommen, dass durch die verbesserten Absatzmengenprognosen weniger Vorräte als Sicherheitsbestand zu halten sind und so die durchschnittlichen Lagerbestände um 25% vermindert werden können. Bei einem durchschnittlichen Lagerkostensatz von 10% (im Wesentlichen die Zinsen auf das gebundene Kapital) führt dies zu einem Anstieg der Umsatzrendite um 0,25%, was bei einem Unternehmen mit 100 Mio. DM Jahresumsatz jährlich 250.000 DM ausmacht. Bezogen auf den Durchschnittsgewinn eines solchen Unternehmens entspricht dies immerhin einer rund 15%igen Gewinnsteigerung.

4. Zusammenfassung und Ausblick

Offensichtlich ist, dass auch mit den besten Frühwarnsystemen die Zukunft nie vollständig vorhersehbar ist; es bleiben Unsicherheiten beispielsweise über die zukünftige Entwicklung von Kundenwünschen, Technologien oder Absatzmengen.

Damit bietet sich für Unternehmen eine zweigleisige Strategie an:

1. Zunächst sollten leistungsfähige Frühwarnsysteme aufgebaut werden, die die zukünftige Entwicklung wesentlicher Variablen möglichst schnell, möglichst präzise und möglichst nachvollziehbar prognostizieren können. Die methodische Grundlage solcher Systeme werden zukünftig immer häufiger neuronale Netze und Kausalanalysen sein, wenngleich bestimmte, eher qualitative Verfahren – wie die Delphi-Methode oder die Szenariotechnik – gerade bei der strategischen Frühaufklärung damit nicht völlig substituierbar sind. Kausalanalytische Methoden sind immer dann besonders zu empfehlen, wenn Ursache-Wirkungs-Beziehungen empirisch geprüft oder transparent gemacht werden sollen oder mit hoher Sicherheit rein zufallsbedingte Korrelationen erkannt werden sollen. Neuronale Netze bieten dagegen den Vorteil, dass sie auch dann verwertbare Ergebnisse liefern, wenn die theoretischen Kenntnisse über die kausalen Abhängigkeitsstrukturen relativ schwach sind oder sehr ausgeprägte nicht-lineare Beziehungen zu behandeln sind. Dafür bestehen – im Vergleich zu kausalanalytischen Methoden – Nachteile bezüglich der Nachvollziehbarkeit der Ergebnisse.
2. Um den unvermeidlichen „Rest-Risiken“ zu begegnen, die auch nach dem Aufbau leistungsfähiger Frühwarnsysteme verbleiben, ist das Unternehmen so flexibel zu gestalten, dass es sich auch an unvorhergesehene Entwicklungen anpassen kann. Dies impliziert beispielsweise den Aufbau verteidigungsfähiger Kernkompetenzen, die in unterschiedlichen Märkten und bei möglichst vielen denkbaren Zukunftsszenarien wertvoll sind. Zudem ist das Risikodeckungspotenzial, also das Eigenkapital so zu dimensionieren, dass damit auch nicht vorhergesehene Risiken abgedeckt werden können und das Unternehmen ausreichend Zeit gewinnt, sich an eine neue Entwicklung anpassen zu können.

Frühwarnsysteme sind ein unverzichtbares Element jeder gezielten Unternehmensteuerung, weil die Qualität der unternehmerischen Entscheidungen von der Qualität der Informationen – insbesondere über zukünftige Entwicklungen – abhängt. Auch wenn nie jede zukünftige Entwicklung vorhergesagt werden kann, so werden doch heute viele prinzipiell vorhandenen Möglichkeiten der Frühaufklärung noch nicht genutzt. Neuronale Netze und Kausalanalysen sind Methoden, die viele der Schwächen in traditionellen Frühwarnsystemen vermeiden, und so qualitativ deutlich bessere Prognosen ermöglichen.