Projekt PARPROG
Parallele Prognoseverfahren für die Absatzplanung

Hans-Paul Schwefel
Joachim Sprave
Mike Preuß
Susanne Rolf
Fachbereich Informatik
Lehrstuhl für Systemanalyse
Universität Dortmund

Rudolf Lewandowski
Stefan Theis
Marketing Systems GmbH
Essen

1 Einleitung

Im Bereich des High-Performance-Computing sind Erfolge bei den sogenannten *Grand Challenges*, den großen Herausforderungen an die Hard- und Software-Entwicklung (z.B. Klimaforschung, Teilchenphysik, Gensequenzierung) besonders spektakulär. Die Erwartung eines Nutzens für die Volkswirtschaft ist dabei aber eher mittel- bis langfristig, da die gewonnenen Erkenntnisse erst noch in Produkte umgesetzt werden müssen. Eine kurzfristige Möglichkeit, die Wettbewerbsfähigkeit der Industrie zu verbessern, ist dagegen die Effizienzsteigerung. Computerunterstütze Planungsverfahren verwenden hierzu meist Methoden des Operations Research. Zu diesen Verfahren sind in den letzten Jahren in zunehmendem Maße Alternativen aus dem Bereich der Computational Intelligence entstanden, insbesondere im Bereich der Logistik, wo viele Probleme auf klassische NP-vollständige Probleme reduziert werden können. Im Rahmen des Projekts PARPROG steht die Absatzplanung im Vordergrund, bei der die Genauigkeit der eingesetzten Prognoseverfahren eine entscheidende Rolle spielt. Da der Prognosehorizont oft im Bereich von wenigen Stunden liegt, bietet sich neben neueren Verfahren aus der Informatik vor allem auch Parallelverarbeitung an.

Die bei Marketing Systems eingesetzten Verfahren beruhen auf Methoden, die Lewandowski[5, 6] in den 70er Jahren entwickelt hat. Im Laufe der Zeit haben sich diese Verfahren nach und nach durch Einbringung von Expertenwissen und Heuristiken zu komplexen, in der Praxis bewährten Modellierungsinstrumenten entwickelt. Mit der Weiterentwicklung der Verfahren ist jedoch auch die Anzahl der externen Parameter gestiegen, die notwendig sind, um ein konkretes Prognosemodell zu entwickeln. Ein Schwerpunkt des Projekts PARPROG ist die Synthese von parallelen Methoden aus der Computational Intelligence mit den bei Marketing Systems eingesetzten Verfahren.

2 Parallele Parameterschätzung mit Methoden der Computational Intelligence

Zusätzlich zu den in der Praxis angewandten Verfahren wurde, gewissermaßen zur Validierung des Ansatzes, zusätzlich ein Zeitreihenmodell gewählt, das sehr gut theoretisch untersucht ist, und zu welchem heuristische Verfahren aus der Statistik existieren, die in Verbindung mit Expertenwissen eine gute Schätzung ermöglichen: Autoregressive Moving-Average-Prozesse (ARMA-Prozesse).

2.1 Modellierung des klassischen ARMA-Ansatzes mit Hilfe paralleler Evolutionärer Algorithmen

Der Box-Jenkins-Ansatz, der die Modellierung eines ARMA-Prozesses beschreibt, ist eines der traditionellen Verfahren der klassischen Zeitreihenanalyse. An dieser Stelle soll die Methodik nur so weit erläutert werden, wie es für das Verständnis der parallelen Parameterschätzung notwendig ist. Eine umfassende Einführung findet sich z.B. in [10].

Ein ARMA[p,q]-Modell hat die Form:

$$x_t = \alpha_1 x_{t-1} + \dots \alpha_p x_{t-p} + \varepsilon_t - \beta_1 \varepsilon_{t-1} - \dots - \beta_q \varepsilon_{t-q},$$

dabei ist x_t die beobachtete Zeitreihe der Länge n, ε_t die Reihe der zugehörigen Zufallsschocks, p die Anzahl der in das Modell eingehenden vergangenen Zeitreihenwerte, q analog die Anzahl der eingehenden Zufallsschocks. Für das Modell wird die Stationarität der Zeitreihe vorausgesetzt, ebenso wie die Unabhängigkeit und Normalverteiltheit der Elemente der Reihe der Zufallsschocks. Der Vorgang der Modellierung umfaßt nun drei Schritte:

- In der ersten Phase der *Modellidentifikation* werden anhand empirischer Funktionen (Autokorrelationsfunktion und Partieller Autokorrelationsfunktion), die aus der gegebenen Zeitreihe ermittelt werden, die Modellordnungen p und q festgelegt.
- Sind die Modellordnungen festgelegt, wird zunächst die Reihe der Zufallsschocks ε_t aus den Residuen eines überlangen AR-Prozesses geschätzt. Existieren nun Schätzer für diese Unbekannten, können im Rahmen der *Parameterschätzung* Schätzer für die Modellparameter $\alpha_1, \dots, \alpha_p, \beta_1, \dots, \beta_q$ ermittelt werden. Dies geschieht entweder durch Maximierung der Likelihoodfunktion, die die zur gegebenen Zeitreihe gehörende Wahrscheinlichkeitsdichte darstellt, oder durch Minimierung der Kleinste-Quadrate-Funktion, die aus den quadrierten Abweichungen zwischen Modell und tatsächlicher Reihe besteht.
- Nachdem nun alle Unbekannten geschätzt wurden, wird in einem letzten Schritt, der *Modelldiagnose* die Güte des Modells überprüft. Dabei wird im wesentlichen durch verschiedenen Tests und Kriterien überprüft, ob die Modellvoraussetzungen eingehalten werden und ob sich keine überflüssigen Parameter im Modell befinden. Unter anderem stehen folgende Modelldiagnosemöglichkeiten zur Verfügung:

- Ljung-Box-Test auf Unkorreliertheit der Residuen. Dieser Test prüft die Voraussetzung der Unabhängigkeit der Elemente der Residualreihe voneinander.
- Überprüfung der Stationarität des Modells. Um diese Voraussetzung zu untersuchen, wird das charakteristische Polynom des AR-Teils des Modells aufgestellt und seine Nullstellen berechnet. Liegen alle diese Nullstellen außerhalb des komplexen Einheitskreises, so ist das Modell stationär.
- t-Test auf Gleichheit einzelner Parameter mit Null. Stellt sich heraus, daß Parameter von Null nicht signifikant zu unterscheiden sind, sollten sie aus dem Modell entfernt werden.
- Vergleich verschiedener Modelle durch Informationskriterien, die sowohl die Anpassung als auch die Anzahl der benutzten Parameter in Betracht ziehen.

2.2 Einbettung der ARMA-Methode in den Evolutionären Algorithmus

Die oben genannten drei Schritte der ARMA-Modellidentifikation sollen nun durch den Evolutionären Algorithmus in Form eines gemischt-ganzzahligen Optimierproblems verarbeitet werden. Dabei werden alle Unbekannten des ARMA-Modelles, d.h. sowohl die Modellordnungen p und q als auch die Modellparameter $\alpha_1, \ldots, \alpha_p, \beta_1, \ldots, \beta_q$ und die geschätzte Reihe der Zufallsschocks ε_t im Verlauf des Verfahrens optimiert.

2.2.1 Definition der Fitnessfunktion

Da die Aufstellung einer Likelihoodfunktion im Falle des ARMA-Modells wegen der großen Matrizen, die sie enthält, recht schwierig ist, stützt sich das Verfahren auf die Parameterschätzung mit Hilfe des Kleinste-Quadrate-Abstandes. Damit hat die Fitnessfunktion die Form:

$$\sum_t [x_t - (\alpha_1 x_{t-1} + \ldots + \alpha_p x_{t-p} - \beta_1 \varepsilon_{t-1} - \ldots - \beta_q \varepsilon_{t-q})]^2.$$

Mit Hilfe dieser Funktion wird nun jedes vom Evolutionären Algorithmus vorgeschlagene Individuum bewertet. Ein solches Individuum besteht dabei aus den ganzzahligen Parametern p und q sowie dem reellen Vektor der Modellparameter $\alpha_1, \ldots, \alpha_p, \beta_1, \ldots, \beta_q$.

2.2.2 Schätzung der Reihe der Zufallsschocks

Die Schätzung der Reihe der Zufallsschocks beeinflußt die gesamte Modellanpassung in hohem Maße. Von ihrer Qualität hängt ab, wie gut die eigentliche Schätzung der Parameter gelingen kann. Daher ist besonders hier ein exaktes Ergebnis erstrebenswert.

Im hier vorgestellten Verfahren findet die Schätzung der Zufallsschocks - abweichend von den traditionellen statistischen Methoden - nicht von der eigentlichen Parameterschätzung entkoppelt statt, sondern ist vielmehr ebenfalls einer ständigen Anpassung und Verbesserung unterworfen: Es wird nicht vorab einmalig eine solche Reihe geschätzt und dann fortlaufend für die Parameterschätzung genutzt, sondern es wird jeweils pro Generation eine neue Reihe als vorläufige Schätzung ermittelt. Dabei wird in jeder Generation das Individuum mit der besten Fitness ausgewählt, die zugehörige Residualreihe wird dann als geschätzte Reihe der Zufallsschocks für die nächste Generation benutzt.

Mit diesem Ansatz kommt zum Problem der gemischt-ganzzahligen Optimierung auch noch die Schwierigkeit der nicht-konstanten Umwelt. Das bedeutet, daß das gleiche Individuum zu verschiedenen Zeitpunkten der voranschreitenden Modellanpassung durchaus verschiedene Fitnesswerte erhält, da sich die Zielfunktion von Generation zu Generation verändert. Dennoch erweist sich der Ansatz in der Anwendung als sehr günstig zur schnellen und präzisen Schätzung der Reihe der Zufallsschocks.

2.2.3 Abwicklung der Modelldiagnose

Neben einer guten Anpassung wird von einem vorgeschlagenen Modell in der klassischen Zeitreihenanalyse nun noch die Erfüllung diverser Kriterien verlangt. Verschiedene Überprüfungen können dabei durchaus ein Modell disqualifizieren oder zumindest als fraglich kennzeichnen. Für das hier vorgestellte Verfahren stellt sich nun speziell die Frage, ob die Modelldiagnosetools zur korrekten Auffindung des Modelles unter Umständen einen Beitrag leisten können. Aus diesem Grunde wurde das Verhalten des Algorithmus mit hinzugefügten Tests und Kriterien untersucht.

Die Einführung eines solchen Kriteriums bietet sich im Allgemeinen in Form einer Restriktion an. So wurden sowohl der Test auf Stationarität als auch auf Unabhängigkeit der Residuen zur reinen Beurteilung der Fitness hinzugefügt. Der t-Test auf Gleichheit eines Parameters mit Null hingegen ist nicht als Restriktion zu behandeln. Er wurde vielmehr als Möglichkeit in Betracht gezogen, die Ordnungen der vorgeschlagenen Modelle auf diesem Weg zu verringern indem diejenigen Parameter, die für nicht signifikant von Null verschieden befunden wurden, aus dem Modell entfernt wurden.

Ebenfalls nicht als Restriktionen aufgefaßt werden können die oben vorgestellten Informationskriterien, die mehr auf den Vergleich verschiedener Modelle ausgelegt sind. Sie bieten sich daher eher als Teile der Zielfunktion oder als seperate Zielfunktionen an. Aus dieser Tatsache heraus ergibt sich die Idee einer Untersuchung der Möglichkeiten der multikriteriellen Optimierung im Zusammenhang mit dem vorliegenden Problem.

3 Parallele Evolutionäre Algorithmen

Evolutionäre Algorithmen (EA) sind eine Klasse von Verfahren zur Parameteroptimierung, die nach dem Vorbild der natürlichen Evolution Testpunkte im Suchraum wie eine Population von Individuen in einer künstlichen Umwelt behandeln. Durch Nachahmung von Prinzipien wie ungeschlechtlicher oder gechlechtlicher Fortpflanzung (Reproduktion ohne oder mit Rekombination) und zufällige, kleine Änderungen (Mutation) können neue Punkte erzeugt werden. In Anlehnung an das Darwinsche Evolutionsmodell wird aber dafür gesorgt, daß nur gut angepaßte Individuen überleben oder zumindest mehr Nachkommen haben. An die Stelle der Umwelt zur Bestimmung der Qualität (Fitneß) eines Individuums tritt in EA die Zielfunktion, die es zu optimieren gilt. So entsteht eine Folge von Generationen mit in der Regel ansteigender durchschnittlicher Qualität.

Die wichtigsten Vertreter dieser Verfahren sind Genetische Algorithmen (GA) [4, 1] und Evolutionsstrategien (ES) [7, 11]. Einen ausführlichen Vergleich der Verfahren haben Hoffmeister und Bäck [3] vorgestellt.

4 Parallelisierung

Durch die Modellierung von Populationen verfügten EA von Anfang an über eine inherente Parallelität, so als wären sie für die heute verfügbare Höchstleistungs-Hardware konzipiert worden. Es gibt nur eine einzige Operation, die nicht auf triviale Weise parallel auf allen Individuen durchgeführt werden kann: Zur Selektion wird Wissen über die Fitneß aller Individuen einer Population verwendet. Globales Wissen aber führt zwangsläufig zu Synchronisationspunkten und Wartezeiten und somit zu einer geringen Effizienz. Will man nun die Selektion so verändern, daß man einen großen Teil der benötigten Daten lokal auf jedem Prozessor halten kann, so kann man sich weiterer Vorbilder aus der Natur bedienen.

4.1 Das Migrationsmodell

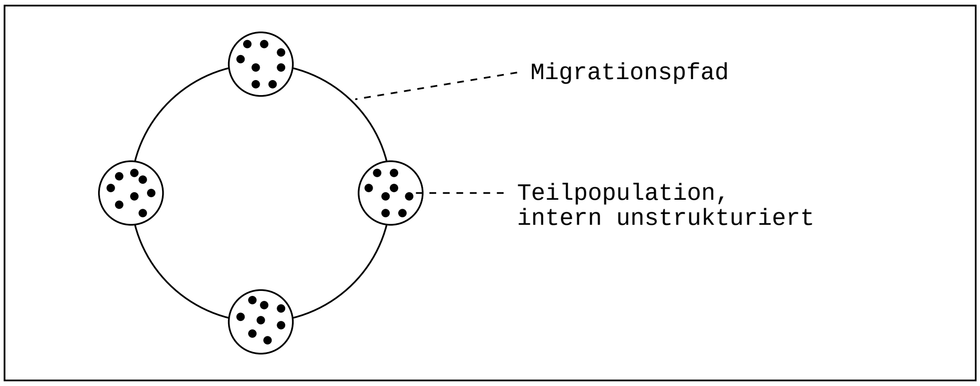

Abb. 1: Topologie des Migrationsmodells

Der Parallelisierungsansatz nach dem Migrationsmodell zerlegt die Gesamtpopulation in mehrere Teilpopulationen, die jeweils lokal auf einem Prozessor einem nahezu unveränderten EA unterzogen werden. Allerdings werden in gewissen Abständen einige Individuen zwischen den Teilpopulationen ausgetauscht, so daß alle Populationen von den Fortschritten der anderen schließlich profitieren können. Die dadurch erreichte Verzögerung der Informationsausbreitung ist keineswegs von Nachteil: Bei Optimieraufgaben mit mehreren lokalen Optima läuft jede Teilpopulation auf ein lokales Optimum zu und hätte im sequentiellen Fall kaum eine Chance, dessen Attraktionsbereich zu verlassen. Durch das Vorhandensein mehrerer Teilpopulationen können unterschiedliche lokale Optima gleichzeitig gefunden werden, die durch Rekombination mit Migranten auch wieder verlassen werden können.

Besonders effizient wird dieser Ansatz, wenn man die Forderung aufgibt, daß alle Teilpopulationen sich immer in der gleichen Generation befinden. Dank der Robustheit der EA ist es möglich, die Migranten mittels asynchroner Kommunikation auszutauschen und somit ganz ohne Synchronisation auszukommen. Untersuchungen von Rudolph [8] haben gezeigt, daß eine paralle Evolutionsstrategie nach dem Migrationsmodell globale Optimierprobleme lösen kann, bei denen sequentielle Varianten so gut wie nie erfolgreich sind.

4.2 Das Nachbarschaftsmodell

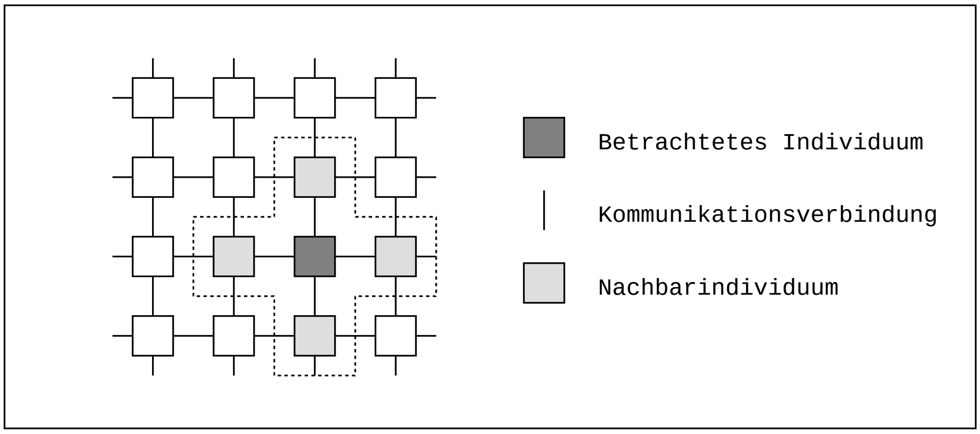

Abb. 2: Topologie des Nachbarschaftsmodells

Ein anderer Parallelisierungsansatz beruht auf der Vorstellung, daß immer nur benachbarte Individuen miteinander in Konkurrenz stehen. Um dies zu modellieren, muß man zunächst die Individuen in einer Topologie, etwa Ring oder Torus, plazieren und hierauf eine Nachbarschaftsbeziehung definieren. Nachbarn eines Individuums sind dann beispielweise alle direkt angrenzenden Individuen. Tatsächlich ist weniger die Form als vor allem die Größe der Nachbarschaften von Bedeutung. Zu jedem Platz in der Population wird nun ein Nachkomme ermittelt, indem Eltern aus der Nachbarschaft selektiert, rekombiniert und mutiert werden. Aktualisiert man alle Individuen synchron, so erhält man einen probabilistischen zellulären Automaten.

Die ersten Implementierungen verwendeten meist die physikalische Topologie des Kommunikationsnetzwerkes und plazierten genau ein Individuum je Prozessor [2]. Dies führt zu feinkörniger Parallelität mit hohem Kommunikationsaufwand. Ordnet man dagegen jeweils ein Teilgitter mit mehr als einem Individuum einem Prozessor zu [12], so erhält man bezüglich Asynchronität und Skalierbarkeit die gleichen Eigenschaften wie beim Migrationsmodell. Parallele EA nach dem Nachbarschaftsmodell eignen sich besonders zur Breitensuche, da durch den langsamen Informationsfluß über viele Generationen ein hohes Maß an Diversität aufrecht erhalten werden kann. Dies gilt insbesondere dann, wenn man die Teilpopulationen nicht nach jeder Generation ihre Ränder mit den Nachbarpopulationen austauschen läßt, sondern durch längere Isolationsphasen ermöglicht, daß unterschiedliche Attraktionsgebiete des Suchraums auf verschiedenen Prozessoren erforscht werden.

Im Rahmen des Projekts wird ein Nachbarschaftsmodell mit parametrisierbarer Isolationszeit eingesetzt. Für die lokale Selektion wurden kanonische Erweiterungen der klassischen (μ, λ)-Selektion der Evolutionstrategie implementiert, wie sie in [13] vorgeschlagen wurden. Die Wahl der Nachbarschaftsgrößen beruht auf einer unter Beteiligung des Projekts PARPROG entstandenen Parameterstudie[9].

5 Real-World-Anwendungen im Projekt PARPROG

5.1 Prognose für die Absatzplanung

Die Unternehmensplanung erfordert fundierte Prognosen für den kurz-, mittel- und langfristigen Zeithorizont. Jede derartige Prognose beruht letztendlich auf einer Analyse der Entwicklung in der Vergangenheit, deren wesentliche Entwicklungsmerkmale durch ein mathematisch-statistisches Modell beschrieben werden. Unter der Hypothese, daß in der Zukunft keine wesentlichen Änderungen des Konsumentenverhaltens zu erwarten sind, kann dieses Modell zur Prognose verwendet werden.

Um den realen Verhältnissen des Marktes gerecht zu werden, müssen möglichst alle Einflußvariablen in der Modellierung berücksichtigt werden. Dies führt zu einer hohen Komplexität der verwendeten Modelle, welche in der Regel durch die Anzahl der zu schätzenden Parameter definiert ist.

Darüber hinaus müssen die Prognosen häufig schnell verfügbar sein (beispielsweise tägliche oder wöchentliche Updates) um stets auf die aktuelle Entwicklung reagieren zu können. In Kombination mit einem komplexen Modell ist damit in vielen Anwendungsfällen der Zeitaspekt von zentraler Bedeutung.

Mit Hilfe von parallelen evolutionären Algorithmen können derartige Optimierprobleme effizient bearbeitet werden. Im Folgenden wird an einem einfachen Beispiel aus der Praxis die mögliche Komplexität der Fragestellung dargestellt.

5.2 Prognose des Absatzes eines Pkw-Modells

Die beschriebene Methodik basiert auf dem sogenannten Consumer Behaviour Forecasting. Dieser Ansatz wurde von Lewandowski [6] entwickelt und ermöglicht die Beschreibung der wahren Markt- bzw. Konsumentenreaktion. Das Verfahren hat sich in über 10jähriger Praxis in umfangreichen Anwendungsfeldern als laufendes operatives und strategisches Instrument zur Prognose und Simulation bewährt. Die besondere Bedeutung des Verfahrens für die Unternehmensplanung ist in [14] dokumentiert.

Ein Automobilhersteller bringt in einigen Monaten eines seiner Modelle neu auf den Markt. Es stellt sich die Frage, zu welchem Preis und mit welcher Serienausstattung ein optimaler Absatz des neuen Modells erzielt werden kann.

Ziel der Analyse der Entwicklung in der Vergangenheit ist daher insbesondere die Identifikation der Einflüsse der Marketing-Variablen:

- Preis
- Ausstattung
- Modellpolitische Maßnahmen

Darüber hinaus ist die gesamtwirtschaftliche Entwicklung zu berücksichtigen. Dazu können beispielsweise die sozioökonomischen Indikatoren des Bruttosozialproduktes oder der Arbeitslosenrate verwendet werden.

Anhand des Beispiels der Marketing-Variable Preis sollen die einzelnen Modellschritte dieser explikativen Analyse erläutert werden:

5.3 Konsumentenwahrnehmung

Zunächst ist die dynamische Veränderung in der Wahrnehmung der Konsumenten zu beachten. Ein Preis von beispielsweise 30.000 DM kann nur in Verbindung mit der Preisentwicklung beurteilt werden, d.h. unter Berücksichtigung des Preises in den vorangegangenen Monaten. Daraus läßt sich der von den Konsumenten als "normal" empfundene Preis ableiten, der auch als Akzeptanzpreis bezeichnet wird.

Dieser dynamische Akzeptanzpreis kann mit Hilfe eines mathematischen Modells über den gesamten Zeitraum beschrieben werden. Die Differenz zwischen dem tatsächlichen Preis und dem Akzeptanzpreis geht als Konzeptvariable in die weitere Modellierung ein.

5.4 Konsumentenreaktion

Die Reaktionen der Konsumenten auf Veränderungen der Konzeptvariablen sind typischerweise nicht linear. Bei kleinen Änderungen der Konzeptvariablen treten praktisch keine Absatzänderungen auf. Wird der Preis dagegen stärker angehoben, wird die Differenz gegenüber dem Akzeptanzpreis als signifikant wahrgenommen und entsprechend treten deutlich negative Reaktionen auf. Bei noch weiteren Preiserhöhungen werden häufig Sättigungseffekte für den Absatzrückgang festgestellt. Bei Preissenkungen sind ähnliche Reaktionen zu erwarten, aber in positiver Richtung.

Der Typ der Elastizitätskurve, die obige Reaktionen beschreibt, basiert auf Erfahrungswerten. Durch ein allgemeines mathematisches Modell mit mehreren Parametern kann diese Funktion jedoch variiert werden. Die problemspezifische Elastizitätskurve bzw. deren Parametrisierung ist für jede Anwendung zu optimieren.

5.5 Zeitdynamik

Das dritte Element der hier gezeigten typischen Modellelemente ist der Zeitverzögerungseffekt. Eine starke Preisanhebung hat gemäß der vorher gezeigten Preiselastizität in derselben Periode einen deutlichen negativen Einfluß. Der Effekt ist aber nicht sofort danach beendet, da sich beispielsweise abgewanderte Käufer eventuell kurzfristig nicht mehr um die Preisgestaltung des betreffenden Produktes kümmern oder ihre Wahrnehmung aktualisieren: Es bleibt als Erinnerung: "Produkt zu teuer", obwohl möglicherweise inzwischen das betreffende Produkt wieder ein normales Preisniveau erreicht hat. Der negative Effekt baut sich also im Verlauf der Zeit nur langsam wieder ab.

Auch die Zeitdynamik wird durch eine mathematische Funktion mit mehreren Parametern beschrieben, die für jede Anwendung zu adaptieren sind.

Insgesamt ergibt sich damit für die Variable Preis ein dreistufiges Modell, dessen Parameter für jede Anwendung bestimmt werden müssen. Dabei ist zu berücksichtigen, daß die Parameter der zweiten und dritten Stufe von den Parametern der vorhergehenden Stufen abhängen. Prinzipiell wird für jede Einflußvariable eine derartige Modellierung ihres Einflusses verwendet. Die gesamte Modellierung der Entwicklung in der Vergangenheit setzt sich aus den einzelnen Modellen zusammen, wobei die Interaktionen zwischen den Variablen zusätzlich berücksichtigt werden müssen.

Insgesamt ergibt sich in diesem Beispiel ein Modell mit etwa 30 Parametern, die alle zu optimieren sind. Eine mögliche Überanpassung des Modells kann durch die Integration von Expertenwissen verhindert werden. Dies kann beispielsweise durch eine Einschränkung der möglichen Parameterwerte in die parallele Optimierung integriert werden.

Die Optimierung der Parameter der Modellierung ist der Kern der gesamten Analyse. Aus den gewonnenen funktionalen Zusammenhängen können Prognosen unter Verwendung gewisser Szenarien für die Einflußvariablen gewonnen werden. Durch die Variation der Szenarien kann die zukünftige Entwicklung simuliert werden.

Beispielsweise kann der Hersteller verschiedene Kombinationen aus Preis und Ausstattung analysieren und diejenige mit dem maximalen Umsatz ermitteln. Damit besitzt der Hersteller ein Instrument zur Optimierung seiner Marketing-Mix-Strategie.

6 Ergebnisse

6.1 Ziel der Experimente

Alle im Projekt entworfenen Verfahren wurden mit PVM unter dem Betriebssystem Solaris entwickelt. Am Lehrstuhl für Systemanalyse sind zur Zeit über 50 Workstations installiert, von denen ein großer Teil nachts oder am Wochenende für parallele Anwendungen genutzt werden kann. Zusätzlich verfügt der Lehrstuhl über ein ParsyTec Power-Xplorer-System mit 16 Prozessoren vom Typ PC601.

Bei den ARMA-Prozessen wurde ausschließlich mit synthetischen Zeitreihen getestet. Ziel der Untersuchung war es, die Ergebnisse der variabeldimensionalen Parameterschätzung mit der Kombination aus Expertenwissen und Anwendung der Box-Jenkins-Methode zu vergleichen. Insbesondere wurde untersucht, welche Auswirkung die Parallelisierung auf die Qualität der Ergebnisse hat.

Bei den Experimenten mit den bei Marketing Systems eingetzten Methoden war die Anzahl der Parameter konstant, so daß keine Modellordnung, sondern nur die Anpassung zu optimieren war. Hierbei stellte sich die Frage, ob das gewählte Qualitätskriterium, nämlich der Fit in der Vergangenheit, ausreicht, um das Expertenwissen zu ersetzten, das beim interaktiven Einstellen der Modellparameter einfließt.

6.2 ARMA-Modellierung

Zunächst stellt sich heraus, daß das oben genannte Verfahren zur Schätzung der Reihe der Zufallsschocks schon nach wenigen Generation sehr exakte Ergebnisse erzielt. Wie aus Abb. 3 ersichtlich, fällt die mittlere absolute Differenz zwischen der geschätzten und der tatsächlichen simulierten Reihe exponentiell. Bereits nach 18 Generationen ergibt sich hier eine mittlere Differenz von etwa 0.1, was im Vergleich zur Varianz der simulierten Reihe ($\sigma^2 = 1$) ein wirklich gutes Ergebnis darstellt. Die hier dargestellte Funktion ist dabei keineswegs eine Mittelung über alle Fälle, sondern vielmehr ein exemplarischer Fall einer Anpassung.

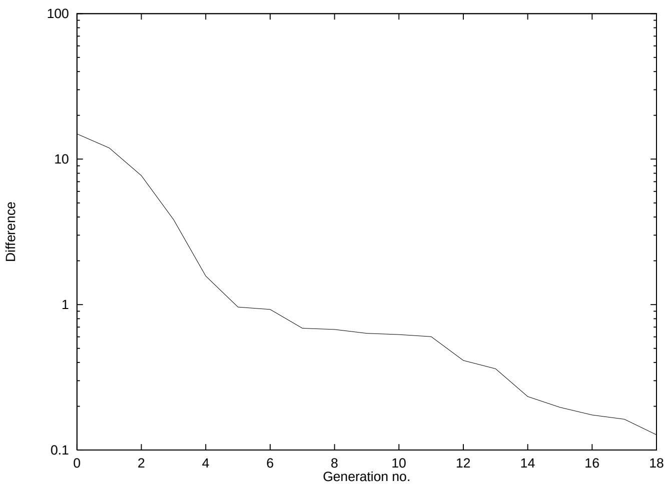

Abb. 3: Typischer Abstieg der mittleren absoluten Differenz zwischen den tatsächlichen Fehlern der synthetisch generierten Zeitreihe und den durch den EA geschätzten Zufallsschocks, dargestellt über die ersten 18 Generationen.

Ein weiteres sehr erfreuliches Ergebnis ist der durch den Einsatz des Evolutionären Algorithmus erzielte Fit des Modells. Dank der Verfügbarkeit statistischer Analysesoftware fällt hier der Vergleich zu den klassischen Verfahren sehr leicht. Es stellt sich heraus, daß der erreichte Kleinste-Quadrate-Abstand sich sehr wohl mit den traditionellen Verfahren messen kann und sie sogar oft in diesem Punkt übertrifft.

Die variabel-dimensionale Parameterschätzung mittels Evolutionärer Algorithmen stellt ein besonderes Problem dar, das bereits in anderen Anwendungsfällen den Einsatz massiver Parallelität erforderlich gemacht hat. Bei den ersten Parameterstudien lag die Identifikation der korrekten Modellordnung durch einen sequentiellen EA bei nur ca. 20% der untersuchten Zeitreihen. Dagegen konnte die Erfolgsquote durch den Einsatz des oben beschriebenen parallelen EAs nach dem Nachbarschaftsmodell auf knapp 40% gesteigert werden. Den Durchbruch aber brachte die Einführung von Isolationszeiten zwischen benachbarten Teilpopulationen. Die ersten Ergebnisse einer Parameterstudie, die zur Zeit erstellt wird, deuten auf eine Fehlerquote von weniger als 10% hin.

Die Einführung der oben genannten Restriktionen besserte bisher den Ausgang der Versuche nicht:

Das Hinzufügen von t-Tests um die Modellordnungen herunterzusetzen zeigte keine deutlichen Auswirkungen und scheint daher als Restriktion nicht stark genug zu sein. Es wird nun über die Konstruktion von vom α-Niveau unabhängigen Konfidenzintervallen nachgedacht um diejenigen Parameter auszusortieren, die sehr nahe bei Null liegen. Ähnlich wie der t-Test verhielt sich auch der Test auf Stationarität, der nur sehr wenige vorgeschlagenen Modelle disqualifizieren konnte. Diese Beobachtung an sich ist nicht verwunderlich, da von vornherein zu hoffen war, daß der Algorithmus an eine stationäre Zeitreihe auch ein stationäres Modell anpassen würde. Insofern handelt es sich hierbei um ein eher positives Ergebnis.

Im Gegensatz zu den bis dato eingeführten Modelldiagnoseverfahren schränkte die Erweiterung des Verfahrens um den Test auf Unkorreliertheit der Residuen den Suchraum zu stark ein. Der Algorithmus konnte mit dieser Restriktion keine Lösungen im zulässigen Bereich mehr finden. Es wird nun erwogen, die zum Test gehörende Teststatistik nicht zur Überprüfung der Restriktion sondern als Teil der Zielfunktion oder weitere Zielfunktion zu nutzen. Kann kein in diesem Sinne gültiges Individuum gefunden werden, so soll jedoch zumindest ein solches mit geringer Korrelation der Residuen bevorzugt werden.

6.3 Angewandte Absatzprognose

Auch hier zeigt sich ein ähnliches Bild wie bei der ARMA-Schätzung: Bezogen auf das gegebene Optimalitätskriterium werden durchweg bessere Ergebnisse erzielt als mit klassischen Verfahren. Bild 3 zeigt einen Schnappschuß einer EA-Schätzung der Parametrisierung eines fiktiven Pkw-Absatzszenarios zusammen mit den tatsächlichen Werten. Die bei der Simulation verwendeten Parameter werden bei 9 von 12 Parametern sehr gut angenähert. Parameter 11 und 12 hängen im Modell linear voneinander ab, so daß tatsächlich nur das eingestellte Verhältnis von Bedeutung ist. Lediglich Parameter 9 wird noch deutlich zu hoch geschätzt. Es ist zu erwarten, daß bei längerer Laufzeit oder größerer Population auch dieser noch angepaßt würde.

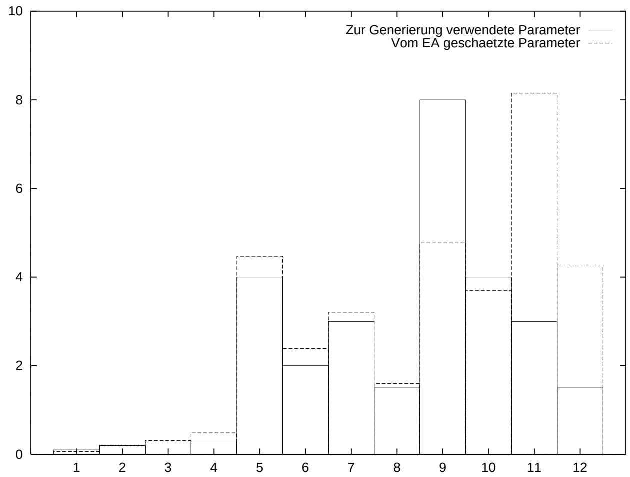

Abb. 4: Vergleich zwischen den Parametern eines simulierten Modells und von einem parallelen EA geschätzten Werten.

7 Bewertung und Ausblick

Die hier vorgestellten Teilergebnisse des Projekts PARPROG haben gezeigt, daß die Synthese klassischer Zeitreihenmethoden und neuerer Methoden aus der Informatik zu praxistauglichen Gesamtverfahren führt. Der Bedarf an Rechenzeit, den probabilistische Verfahren mit sich bringen, wird durch die effiziente Parallelisierbarkeit relativiert. Für die hier vorgestellten Methoden zur mittel- und langfristigen Prognose reicht die Rechenleistung eines kleinen PC-Clusters aus, wobei sogar auf eine teuere Hochgeschwindigkeitsvernetzung verzichtet werden kann. Für die kurzfristige Prognose wird zwar mehr Rechenleistung benötigt, als ein KMU normalerweise zur Verfügung hat, jedoch rechtfertigt die zu erwartende Qualitätssteigerung der Ergebnisse die Anmietung von Rechenzeit bei Höchstleistungsrechenzentren.

Die qualitative Verbesserung der Modellanpassung vorhandener Prognosesysteme ist eine Möglichkeit, die Akzeptanz von CI-Methoden in den Unternehmen zu erhöhen, da die zugrundeliegenden Verfahren nicht verändert werden. Im weiteren Verlauf des Projekts PARPROG wird sich nun zeigen, ob auch künstliche Neuronale Netze sinnvoll mit den vorhandenen Methoden kombiniert werden können. Wiederum wird hierbei skalierbare Parallelität zum Einsatz kommen, um in den engen Zeitrestriktionen qualitative Verbesserungen erzielen zu können.

Literatur

[1] D. E. Goldberg. *Genetic algorithms in search, optimization and machine learning.* Addison Wesley, Reading, MA, 1989.

[2] M. Gorges-Schleuter. ASPARAGOS: an asynchronous parallel genetic optimization strategy. In J. D. Schaffer, editor, *Proceedings of the 3rd International Conference*

on Genetic Algorithms, pages 422–427. Morgan Kaufmann Publishers, San Mateo, CA, 1989.

[3] Frank Hoffmeister and Thomas Bäck. Genetic algorithms and evolution strategies — similarities and differences. Papers on Economics & Evolution 9103, European Study Group for Evolutionary Economics (ESGEE), November 1991.

[4] J. H. Holland. *Adaptation in natural and artificial systems.* The University of Michigan Press, Ann Arbor, MI, 1975.

[5] Rudolph Lewandowski. *Prognose- und Informationssyteme und ihre Anwendungen — Band I.* de Gruyter, Berlin, 1974.

[6] Rudolph Lewandowski. *Prognose- und Informationssyteme und ihre Anwendungen — Band II.* de Gruyter, Berlin, 1980.

[7] I. Rechenberg. *Evolutionsstrategie: Optimierung technischer Systeme nach Prinzipien der biologischen Evolution.* Frommann–Holzboog, Stuttgart, 1973.

[8] G. Rudolph. Globale Optimierung mit parallelen Evolutionsstrategien. Diplomarbeit, Universität Dortmund, Fachbereich Informatik, 1990.

[9] G. Rudolph and J. Sprave. Significance of locality and selection pressure in the grand deluge evolutionary algorithm. In H.-M. Voigt, W. Ebeling, I. Rechenberg, and H.-P. Schwefel, editors, *Parallel Problem Solving from Nature IV. Proceedings of the International Conference on Evolutionary Computation*, volume 1141 of *Lecture Notes in Computer Science*, pages 686–695. Springer, Berlin, 1996.

[10] Rainer Schlittgen and Bernd H.J. Streitberg. *Zeitreihenanalyse.* Oldenbourg Verlag, 6. edition, 1995.

[11] H.-P. Schwefel. *Numerische Optimierung von Computer-Modellen mittels der Evolutionsstrategie*, volume 26 of *Interdisciplinary Systems Research.* Birkhäuser, Basel, 1977.

[12] J. Sprave. *Parallelisierung Genetischer Algorithmen zur Suche und Optimierung.* Diploma thesis, University of Dortmund, December 1990.

[13] J. Sprave. Linear neighborhood evolution strategy. In A. V. Sebald and L. J. Fogel, editors, *Proceedings of the 3rd Annual Conference on Evolutionary Programming*, pages 42–51. World Scientific, Singapore, 1994.

[14] M.P. Zerres and I. Zerres. *Unternehmensplanung.* Frankfurter Allgemeine Zeitung, Verlagsbereich Wirtschaftsbücher, Frankfurt a.M., 1997.