

Tactical Asset Allocation mit Genetischen Algorithmen

MANUEL AMMANN und CHRISTIAN ZENKNER*

1. EINLEITUNG

Ein grundsätzliches Argument gegen systematische Überrenditen aufgrund erfolgreicher Renditeprognosen folgt aus der Hypothese effizienter Kapitalmärkte (vgl. z. B. FAMA, 1970). So ergäbe sich in effizienten Märkten keine Handelsstrategie für einem Markov Prozess unterliegende Instrumente, welche eine Buy-and-Hold-Strategie outperformen könnte (z. B. KWAN, LAM, SO, YU, 2000). Es wurde allerdings mehrfach gezeigt, dass Aktienpreise nicht einem reinen Random Walk Prozess folgen (vgl. z. B. LO und MACKINLAY, 1988) und dass somit Renditen in einem gewissen Ausmass prognostiziert werden können. Dafür können verschiedene Gründe aufgeführt werden. Einerseits ist eine vollständige Informationseffizienz auch unter der Annahme rationaler Akteure undenkbar, da Informationsverarbeitung mit Kosten verbunden ist (GROSSMANN und STIGLITZ, 1980). Aus diesem Grund kann es möglich sein, aus vergangenen Preisdaten nützliche Informationen zur Prognose zukünftiger Preise, z. B. mittels technischer Analyse, zu gewinnen (vgl. z. B. BROCK, LAKONISHOK und LEBARON, 1992). Andererseits impliziert die Zeitvariabilität der erwarteten Renditen aufgrund der Dynamik des Risikoverhaltens der Akteure im Konjunkturzyklus (vgl. CAMPBELL und COCHRANE, 1999) ebenfalls eine gewisse Prognostizierbarkeit der Renditen und lässt vermuten, dass insbesondere makroökonomische Variablen eine gewisse Prognosekraft bezüglich zukünftiger Aktienrenditen aufweisen können, ohne dass damit Marktineffizienz impliziert würde. Die Erklärungs- und Prognosekraft makroökonomischer Variablen bezüglich der Aktienmarktentwicklung wird in verschiedenen empirischen Studien bestätigt, z. B. IN BREEN, GLOSTEN und JAGANNATHAN (1989), FAMA und FRENCH (1989) und FERSON und HARVEY (1993).

Unter Verwendung statistischer Methoden wie Regressionsanalysen kann die Vorausschbarkeit in out-of-sample tests nachgewiesen werden und in der Form einer theoretischen Handelsstrategie ex-post zur Generierung von Überrenditen umgesetzt werden. OLSON und MOSSMAN (2001) und PESARAN und TIMMERMANN (1995) sind Beispiele für auf Regressionsmethoden beruhende Prognosestudien, welche eine solche

* Schweizerisches Institut für Banken und Finanzen, Universität St. Gallen, Rosenbergstrasse 52, 9000 St. Gallen, Tel. 071/224-7090, Fax 071/224-7088.

E-mail: manuel.ammann@unisg.ch, christian.zenkner@unibas.ch. Manuel Ammann ist Ordinarius für Finance an der Universität St.Gallen, Christian Zenkner ist wissenschaftlicher Mitarbeiter am WWZ der Universität Basel. Die vorliegende Arbeit entstand während seiner Assistenz-tätigkeit an der Universität St.Gallen.

Tactical Asset Allocation Strategie implementieren. OLSON und MOSSMAN (2001) verwenden in ihrer Untersuchung Dividendenrenditen des S&P 500, Inflationsraten, Renditen auf 3 Monats T-Bills bzw. Zahlen zur Industrieproduktion in Verbindung mit aus Kreuz-Korrelationen resultierenden Indikations- und Folgeeffekten zwischen Large- und Small Caps, um Aktienkursrenditen den jeweils auf die in-sample Datensätze anschließenden Folgeperioden prognostizieren zu können. Solange eine positive Überschussrendite der Folgeperiode ermittelt wird, erfolgt ein Aktieninvestment, andernfalls eine Alternativanlage in ein risikofreies Asset. Als Benchmark dient eine Buy-and-Hold-Strategie. Es werden dabei je nach Modellvariante Trefferquoten zwischen 53 % und 55 % bei Aktienanteilen der aktiven Strategien zwischen 45 % und 79 % erreicht. Überschussrenditen können unter Vernachlässigung von Transaktionskosten gezeigt werden, die jedoch unter Berücksichtigung dieses Aspektes verschwinden. Die Transaktionsquoten bzw. Investitionswechselraten zwischen den Assetklassen liegen über die Untersuchungszeitspanne zwischen 20 % und rund 50 %. OLSON und MOSSMAN (2001) erreichen insbesondere während der 80er Jahre gute Resultate.

PESARAN und TIMMERMANN (1995) untersuchen ebenfalls Möglichkeiten, US-Aktienrenditen zu prognostizieren, um Überschussrenditen über eine Buy-and-Hold Strategie in den Marktindex zu erzielen. Für die Untersuchung werden ähnliche, wie bereits im Zusammenhang der Arbeiten von Olson und Mossman erwähnten Prognosevariablen verwendet. Insgesamt werden Trefferquoten der Prognosen in Höhe von 58 % erzielt. Unter der Annahme von Transaktionskosten können aufgrund des varianzreduzierenden Effektes der aktiven Strategien superioren Sharpe-Ratios ausgewiesen werden, obwohl diesfalls keine direkte Outperformance auf Renditebasis gezeigt werden kann. Sowohl die Prognostizierbarkeit von Aktienrenditen als auch der Erklärungsgehalt der Prognosevariablen ist über die Zeit Schwankungen unterworfen, wobei ebenfalls in den 80er Jahren überdurchschnittlich gute Ergebnisse erzielt wurden.

Den bisher erwähnten Arbeiten ist gemeinsam, dass sie mit der klassischen, auf linearen Zusammenhängen basierenden Regressionsmethodik arbeiten. Diese Methodik verlangt, dass funktionale Zusammenhänge im voraus in der Form eines Regressionsmodells spezifiziert werden. Möglicherweise weist die Dynamik der Aktienrenditen aber bedeutende nichtlineare Komponenten auf (vgl. z. B. SCHEINKMAN und LEBARON, 1989) und folgt keinem konstanten, in einer einfachen Modellspezifikation zu erfassenden Zusammenhang. Zur Modellierung hochkomplexer und nichtlinearer Zusammenhänge eignen sich die adaptiven Methoden der künstlichen Intelligenz, wie z. B. neuronale Netze oder genetische Algorithmen besonders gut, vorausgesetzt, es steht eine genügend grosse Datenmenge zur Trainierung des Systems zur Verfügung. Die Anwendung neuronaler Netze für die Renditeprognose hat sich deshalb bislang auf die Prognose von Wechselkursen konzentriert (vgl. z. B. KUAN und LIU, 1995), wo grosse Mengen an High-Frequency Daten verfügbar sind.

TRIPPI und DESIENO (1992) verwenden ein neuronales Netz für kurzfristige Kursprognosen von Aktienindex-Futures zur Umsetzung einer Handelsstrategie, welche den Benchmark Index schlagen soll. Dabei werden als Inputparameter nur Merkmale der

Zeitreihe selbst, nämlich Eröffnungs-, Schluss-, Höchst- und Tiefstkurse sowie Volatilitätsangaben der jeweils letzten zwei Wochen und der Eröffnungskurs und Preisfeststellung 15 Minuten nach Eröffnung des aktuellen Handelstages benutzt. TRIPPI und DE SIENO (1992) erreichen damit eine signifikante Outperformance, verzichten aber auf eine Risikoadjustierung ihrer Resultate.

REHKUGLER und Poddig (1990, 1991) benutzen ebenfalls neuronale Netzwerke, um Aktienkurse zu prognostizieren, verwenden als Informationsquelle aber makroökonomische Daten. Sie vergleichen die mit neuronalen Netzwerken erreichten Ergebnisse mit Resultaten, die mit statistischen Methoden gewonnen werden und kommen zum Schluss, dass die neuronalen Netzwerke den Regressionsmethoden überlegen sind.

ALLEN und KARJALAINEN (1999) versuchen, mit einem genetischen Algorithmus Handelsregeln zu identifizieren, mit welchen Überschussrenditen erzielt werden können. Sie untersuchen dazu eine lange Zeitreihe (1928–1991) täglicher Daten des S&P500 Indexes. Die Regeln werden nur aus der Zeitreihe und davon abgeleiteten Zeitreihen wie Minima, Maxima oder gleitenden Durchschnitten hergeleitet. Die Autoren kommen zum Schluss, dass der Algorithmus keine Regeln findet, welche die systematische Erzielung von Überrenditen nach Abzug der Transaktionskosten ermöglichen würden.

In der vorliegenden Studie wird ebenfalls ein genetischer Algorithmus benutzt, um Handelsstrategien zu identifizieren, welche Überrenditen generieren. Anders als in ALLEN und KARJALAINEN (1999) wird aber dazu nicht die in der Indexzeitreihe enthaltene Information benutzt, sondern auf andere makroökonomische Zeitreihen als Informationsquelle zurückgegriffen. Was die erklärenden Variablen betrifft, ähnelt die Untersuchung folglich OLSON und MOSSMANN (2001) und PESARAN und TIMMERMANN (1995), aber auch Poddig und REHKUGLER (1990). Im Unterschied zu diesen Arbeiten werden hier jedoch nicht Regressionsmethoden oder neuronale Netzwerke, sondern genetische Algorithmen verwendet.

Kapitalmärkte sind vor allem durch komplexe Interdependenzen ihrer Einflussfaktoren gekennzeichnet. Intensitäten, Richtungen und Anzahl der relevanten Größen sind dabei oftmals nicht eindeutig nachvollziehbar. Methoden, die permanente Veränderungsprozesse bewältigen und auf situative und strukturelle Migrationen intelligent reagieren können, erscheinen deshalb besonders vielversprechend. Ausgehend davon, dass Evolution ein sehr robuster Such- bzw. Optimierungsprozess im Raum der genetischen Informationen ist und die damit verbundenen grundlegenden Steuerungsmechanismen selbst komplexeste Organismen in relativ kurzen Zeiträumen an ihre Umwelt- und Lebensbedingungen anzupassen vermögen, repräsentiert das Konzept genetischer Algorithmen eine Problemlösungstechnik, welche zur Renditeprognose auf Aktienmärkten geeignet erscheint.

Ziel dieser Arbeit ist, zu untersuchen, ob mit fünf Erklärungsvariablen und zwei Anlageklassen Kauf- und Verkaufentscheidungen generiert werden können, welche einen Timingerfolg out-of-sample gegenüber einer Benchmarkstrategie aufweisen. Dazu wird ein Konzept entwickelt, mit dem superiore Handelsstrategien im Rahmen eines model-

lierten Suchraumes mit genetischen Algorithmen identifiziert werden. Anhand der Fundamentalvariablen wird für den zugrundeliegenden Betrachtungszeitraum jeweils eine erfolversprechende Verhaltensweise bestimmt. Die dabei implizit gewonnenen Informationen über generelle Zusammenhänge zwischen erklärenden und erklärten Variablen werden dann für jedes Zeitintervall auf out-of-sample Datensätze angewendet, aus denen dann der Markterfolg resultiert.

Zunächst wird dazu in einem ersten Abschnitt das angewandte Methodenkonzept vorgestellt und nachfolgend die Konvergenzeigenschaften des Algorithmus analysiert. Anschliessend wird das Strategie- und Bewertungsmodell sowie das verwendete Datensetup erläutert und die Implementation des Algorithmus beschrieben, bevor in einem weiteren Abschnitt die Ergebnisse der empirischen Untersuchung präsentiert werden.

2. METHODENKONZEPT

Genetische Algorithmen können als naturanaloge Suchverfahren bezeichnet werden, da wesentliche evolutionstheoretische Prinzipien wie Replikation, Variation und Selektion imitiert werden. Sie arbeiten üblicherweise mit einem Populationskonzept, so dass der Lösungsraum von verschiedenen Punkten aus parallel durchsucht wird. Genetische Algorithmen enthalten bewusst stochastische Elemente und keine deterministischen Regeln. Trotzdem entsteht eine intelligente und zügige Durchmusterung des Suchraumes, da sich der Suchprozess auf erfolversprechende Regionen konzentriert. Es existieren keine Einschränkungen bei der Festlegung der Zielfunktion. Genetische Algorithmen eignen sich besonders bei stark nichtlinearen bzw. diskontinuierlichen Zielfunktionen und damit komplexen Problemen, zu deren Lösung sie gegenüber linearen Konzepten wie der Regressionsanalyse wesentliche Vorteile aufweisen. Solange die Population noch hinreichend heterogen ist, ist es genetischen Algorithmen möglich, lokale Optima wieder zu verlassen, was den Beginn der Optimierung von beliebigen Startpunkten aus ermöglicht. Diese Eigenschaft ist ein Vorteil v.a. bei unklaren Topologiemustern des zu lösenden Optimierungsproblems. Als Heuristiken finden genetische Algorithmen nicht notwendigerweise das gesuchte globale Extremum eines gegebenen Problems, doch genügen bei vielen praktischen Problemen mit unklarer Struktur oftmals gute Approximationen.

Nachfolgend werden die dieser Untersuchung zugrundeliegenden Operatoren zur Konfiguration des verwendeten genetischen Algorithmus (GA) vorgestellt. Die Ausführungen folgen dabei dem Aufbau des Basis-GA, wie er aus Grafik 1 ersichtlich ist. Dabei ist jedoch zu betonen, dass für jeden einzelnen Operator grundsätzlich diverse Varianten zur Verfügung stehen, die, da allgemeingültig, auf grosse Bereiche von Problemklassen angewendet werden können.¹

1. Allgemeine Beschreibungen genetischer Algorithmen finden sich z. B. in NISSEN (1994), POHLHEIM (2000), SCHÖNEBURG, HEINZMAN und FEDDERSEN (1994).

Grafik 1: Pseudocode eines Genetischen Algorithmus nach Nissen (1994)

10	Start
20	Generiere Startpopulation (binär) codierter Lösungen auf zufällige Weise
30	Wiederhole
40	Bewerte alle Individuen anhand der Fitnessfunktion
50	Neue Population = { }
60	Solange neue Population noch unvollständig, wiederhole
70	Wähle zwei Individuen mit (z. B.) fitnessproportionalen Wahrscheinlichkeiten als Eltern aus
80	Führe mit Wahrscheinlichkeit P_c ein Crossover durch
90	Mutiere (invertiere) jedes Bit der so entstandenen Nachkommen mit Wahrscheinlichkeit P_M
100	Füge beide Nachkommen zur neuen Population hinzu
110	Schleifenende
120	Alte Population = neue Population (– nächste Generation –)
130	bis Abbruchbedingung erfüllt ist
140	Gib Ergebnisse aus
150	Stop

Die Individuen bzw. Lösungsstrings der Startpopulation wurden gleich verteilt zufällig aus dem vorgegebenen Definitionsbereich ausgewählt. Binäre Variablen können dabei nur die Werte 0 und 1 annehmen. Eine einfache Initialisierungsvariante kann in diesem Fall mit der folgenden Gleichung erreicht werden:

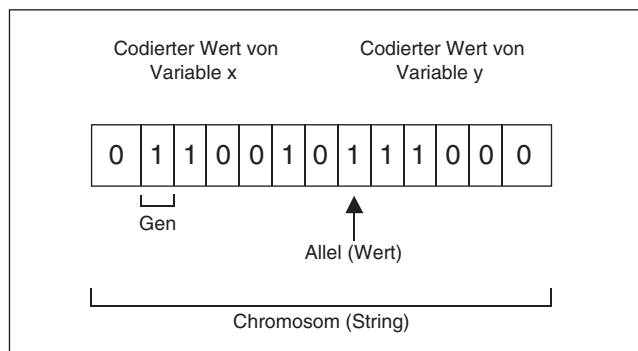
$$Var_i^{binär} = rand_i > 0,5 \quad (1)$$

Der Vergleich liefert 0 für Zufallswerte zwischen 0 und 0,5 sowie 1 für Zufallszahlen grösser als 0,5 bis 1. Solange der Vergleich mit dem Wert 0,5 durchgeführt wird, liegt der Anteil von 1 und 0 in den Individuen bei 50%. Die gesamte Initialisierung besteht aus einer Permutation der Elemente der Individuenstrings (POHLHEIM, 2000). Die gewählte Populationsgrösse pro Generation beträgt in dieser Studie 2300 Individuen.

Genetische Algorithmen arbeiten auf Genotyp-Ebene mit Codierungen der Entscheidungsgrössen einer Problemstellung in Form von Symbolketten (Chromosomen). Die Repräsentation einer individuellen Problemstellung ist dabei von grosser Bedeutung, da die durch sie zum Ausdruck gebrachten Individuenstrings das Material sind, mit dem der genetische Algorithmus arbeitet. Die Operatoren stützen sich hierbei auf eine binäre Darstellung der Grundmenge $M = \{0, 1\}$. Individuen bestehen dabei aus Chromosomen konstanter Länge. Ein Individuum ist somit ein binärer Vektor x und Element aus $M^n = \{0, 1\}^n$, wobei n eine beliebige natürliche Zahl ≥ 1 ist und n die Länge $l(x) = n$ des Vektors bezeichnet. M^n und jede Teilmenge N von M^n wird als Population bezeichnet. Die i -te Position eines Chromosoms $x = \langle \dots, x_i, \dots \rangle \in M^n$

bezeichnet das i -te Gen des Chromosoms. Sein jeweiliger Wert heisst Allel. Gene sind damit Variablen, deren Wert durch das Allel zum Ausdruck gebracht wird, wobei ein Gen auch aus ganzen Abschnitten eines Chromosoms bestehen kann. In der vorliegenden Untersuchung wurde ein aus 28 Bits bestehender Vektor zur Charakterisierung eines Individuums oder Handelsstrategie verwendet, welche aus 14 Genen bzw. Variablen besteht. Grafik 2 verdeutlicht diese Zusammenhänge.

Grafik 2: Schematische Darstellung eines Individuums im Basis-GA, nach Nissen (1994)




Die Bewertungs- und Fitnessfunktion legt das eigentliche Optimierungskriterium fest. Der genetische Algorithmus versucht anhand dessen, durch systematisches Erzeugen möglicher Lösungen das Optimum der Bewertungsfunktion zu finden oder zu approximieren. Die Bewertungsfunktion stellt somit die Verbindung zwischen der individuellen Problemstellung und den Operatoren des Algorithmus her. Dabei misst die Bewertungsfunktion, wie gut ein Individuum das Optimum approximiert, während die Fitness ein Mass für die Wahrscheinlichkeit ist, mit der sich ein Chromosom in der nächsten Generation reproduziert. In dieser Untersuchung wurde eine Selektionsvariante mit proportionaler Fitnesszuweisung benutzt, bei welcher die Fitness eines Chromosoms proportional zum Verhältnis der Bewertung des Individuums zur Summe der Bewertungen aller Chromosomen einer Population errechnet wird. Damit erhält jedes Individuum eine seiner Bewertung (= Güte) direkt proportionale Chance, sich in den folgenden Generationen fortzupflanzen.

Die Selektionskomponente, welche auf Basis der zuvor ermittelten Fitness die Auswahl der Kandidaten für die Erzeugung von Nachkommen durchführt, hat einen wesentlichen Einfluss auf die Richtung der Lösungssuche. Daher spielt die Balance zwischen angemessenem Selektionsdruck und hinreichender Populationsheterogenität eine wichtige Rolle, damit der Algorithmus den optimalen Pfad zwischen dem Erhalten guter Lösungen und damit der Konvergenz sowie der Suche nach neuen, besseren Regionen der Problemtopologie findet. Bei dem hier verwendeten Stochastic Universal Sampling (POHLHEIM, 2000; NISSEN, 1994) werden die Individuen entsprechend ihres absoluten

Fitnesswertes und damit fitnessproportional aus dem Selektionspool ausgewählt. Es handelt sich um ein stochastisches Verfahren, bei dem jedem Individuum auf einer Art Glücksrad ein mit seiner Fitness im Verhältnis zur Gesamtfitness korrespondierender Abschnitt gewährt wird. Auf das Rad weisen in gleichmässigen Abstand angebrachte Zeiger, der Anzahl der n Individuen, so dass das Rad einmal gedreht werden muss, um alle Elternpaare auswählen zu können. Grafik 3 veranschaulicht das Konzept.

Grafik 3: Schema Stochastic Universal Sampling für 4 Individuen (A, B, C, D), nach Nissen (1994)



Der Rekombinationsoperator bestimmt, wie neue Chromosomen aus den zuvor selektierten Elternindividuen gebildet werden. Der Sinn eines gezielten crossing-over-Verfahrens liegt darin, den Suchraum effizient und in grossen Sprüngen zu durchschreiten, was dazu führt, dass genetische Algorithmen kaum in lokalen Minima hängen bleiben. Das Crossover ist ein stochastischer und im Zusammenhang mit der Evolution ungerichteter Prozess, der aber zu einem schnellen Auffinden von Regionen des Suchraumes mit höherer durchschnittlicher Güte im Vergleich zu einer zufälligen Suche führt (SCHÖNEBURG, HEINZMANN und FEDDERSEN, 1994). Der Rekombinationsoperator beeinflusst somit entscheidend die Leistungsfähigkeit, Effizienz und Konvergenzgeschwindigkeit eines genetischen Algorithmus, wobei in die Crossover-Mechanismen problemspezifisches prozedurales Wissen über den Suchraum abgelegt werden kann. Dies hat zur Folge, dass das Crossover den dominierenden Suchoperator genetischer Algorithmen darstellt. Beim Crossover kommt es auf Basis einer im voraus festgelegten Crossover-Wahrscheinlichkeit (hier $P_c = 0,7$) zu einem Austausch der einzelnen Variablen zwischen den Individuen. Prinzipiell wird dabei der Gedanke verfolgt, dass diejenigen Variablen eines Individuums, die am meisten zur Performance beitragen, nicht in einem zusammenhängenden Teil eines Chromosoms enthalten sind. Da der auseinanderreissende Effekt des Crossover als eine verstärkte Breitensuche im Raum angesehen wird, arbeitet dieser Operator dem konvergierenden Element der Selektion entgegen,

was zu einer robusteren Suche führt (POHLHEIM, 2000). Die in dieser Studie verwendete diskrete Rekombination führt einen Austausch der Variablen zwischen den Elternindividuen zur Bildung der Nachkommen durch, indem für jede Variablenposition entschieden wird, von welchem Elternteil der Variablenwert zu verwenden ist, d. h.


$$Var_i^N = Var_i^{E1} \cdot a_i + Var_i^{E2} \cdot (1 - a_i) \quad i \in (1, 2, \dots, Nvar), \quad (2)$$

$a_i \in \{0, 1\}$ mit gleicher Wahrscheinlichkeit


a_i für jedes i neu bestimmt

Diskrete Rekombination erzeugt insofern Nachkommen auf den Eckpunkten eines Würfels, der durch die Variablenwerte der Eltern aufgespannt wird, wie in Grafik 4 dargestellt ist.

Grafik 4: Mögliche Positionen der Nachkommen bei diskreter Rekombination in Bezug auf die Position der Eltern, nach Pohlheim (2000)



Der Mutationsoperator führt zu zufälligen Veränderungen der Individuen. Er verkörpert die zweite Suchkomponente bei genetischen Algorithmen und spielt als lokaler Prozess insbesondere in Suchphasen steigender Individuenhomogenität bei abnehmendem Selektionsdruck und abnehmender Wirksamkeit des Crossoveroperators eine wichtige Rolle. Mutationen dienen vorwiegend dazu, eine vorzeitige Konvergenz der Optimierung zu verhindern und sorgen damit für eine gewisse Divergenz innerhalb der Population. Die Mutation wird im allgemeinen an den Nachkommen durchgeführt, nachdem diese durch Rekombination erzeugt wurden. Die geringe Mutationswahrscheinlichkeit (hier $P_M = 1/(\text{Anzahl der Variablen})$) betont jedoch die primäre Stellung des Crossover-Verfahrens. Der Selektionsdruck und die Bewertungen der Individuen führen im Laufe der Generationen zu immer homogeneren Populationen. Die Aufgabe der Mutation besteht darin, als Hintergrundoperator dieser Tendenz entgegenzuwirken. Bei der Mutation von Individuen mit binärer Codierung wird jedes Bit eines Chromosoms im Rahmen der Mutationswahrscheinlichkeit gleich verteilt zufällig invertiert.

Grafik 5: Schema Mutation eines Individuums mit binären Variablen, nach Pohlheim (2000)

Nachdem die Nachkommen durch Rekombination und Mutation produziert worden sind, müssen sie in die Population eingefügt werden. Bei dem sich daraus ergebenden Wiedereinfügungsschritt ist zu entscheiden, wie viele und welche Nachkommen eingefügt werden bzw. welche Individuen der Population durch die einzufügenden Nachkommen ersetzt werden. Das verwendete Ersetzungsschema steuert, ähnlich wie die Selektionskomponente, die Balance zwischen Selektionsdruck sowie ausreichender Vielfalt des Genmaterials und ist somit für das Konvergenzverhalten des Algorithmus ein wesentliches Element. Anhand zweier Parameter (Wiedereinfügerate und Generationslücke) können Ersetzungsschemata charakterisiert werden. Die Wiedereinfügerate gibt dabei an, wie viele Individuen einer Population maximal durch Nachkommen zu ersetzen sind, während die Generationslücke ein Mass für die Anzahl der produzierten Nachkommen darstellt. Mit einer Generationslücke von 0,98 und einem Selektionsdruck von 1,1 ergab sich in der vorliegenden Untersuchung eine Elitest Reinsertion. Bei dieser Variante ist entweder die Wiedereinfügerate oder die Generationslücke kleiner als 1,0. Damit ist sichergestellt, dass auf jeden Fall weniger Nachkommen als Individuen in der Population in die Nachfolgegeneration eingefügt werden. Indem nur die schlechtesten Individuen ersetzt werden ist gewährleistet, dass ein Austausch der besten Chromosomen einer Population (Eliten) nur dann stattfindet, wenn bessere Individuen gefunden werden. Ist dabei die Generationslücke kleiner als 1,0 (hier der Fall), werden zwar wie bei der einfachen Wiedereinfügung alle erzeugten Individuen in die Nachfolgegeneration übernommen, die besten Chromosomen jedoch einfach nicht ersetzt. Da ein Individuum somit über mehrere Generationen in der Population auftreten kann, stellt die Berücksichtigung des Alters eines Individuums eine mögliche Erweiterung des Reinsertionskonzeptes dar. Die Grundidee liegt darin, dass Individuen, die im Moment noch keine anderen Elemente in der Population finden, aus deren Rekombination bessere Lösungen generierbar sind, trotzdem gutes Erbmateriale enthalten können. Es kann deshalb sinnvoll sein, Chromosomen überdurchschnittlich guter Eltern im Genpool "aufzubewahren", bis die Voraussetzungen für eine erfolgreiche Rekombination erfüllt sind (POHLHEIM, 2000).

Der Optimierungsprozess des genetischen Algorithmus läuft über so viele Generationen, bis ein definiertes Abbruchkriterium erreicht ist. Dieses sollte sich dadurch auszeichnen, dass nach Beendigung der Optimierung ein ausreichend gutes Ergebnis erzielt

wird und der Algorithmus nicht mehr Berechnungen vornimmt, als zum Erreichen dieses Zieles erforderlich sind. In dieser Studie wird die Optimierung nach spätestens 200 Generationen abgebrochen. Neben der leichten Überschaubarkeit und dem garantierten Abbruch kann durch diese Vorgabe gleichzeitig der Optimierungsaufwand beschränkt werden, da die Rechenzeit i. d. R. linear mit der Anzahl der Generationen steigt.

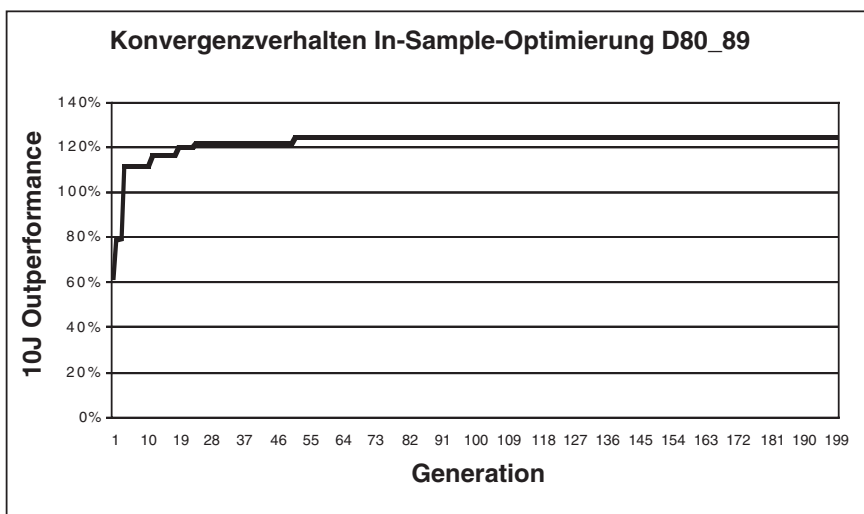
3. KONVERGENZ

Die beschriebenen Einstellungen liessen eine effiziente Optimierung zu und gewähren gleichzeitig einen ausreichenden Spielraum zur Konvergenz. Es hat sich gezeigt, dass die anhand vorliegender Konfiguration identifizierten Lösungen und Ergebnisse mit einer hohen Quote reproduzierbar sind, was als Hinweis für die Tauglichkeit des Algorithmus im globalen Bereich aufgefasst werden kann. Mit einer Individuenzahl von 2300 und einer Generationenzahl von 200 werden pro Optimierungslauf jeweils eine Gesamtzahl von 460'000 möglichen Strategien überprüft. Obwohl dies im Verhältnis zum Gesamtsuchraum nur einen sehr kleinen Anteil darstellt, konnten auch bei diversen Variationen der Individuen- und/oder Generationenzahlen keine überlegenen Lösungen identifiziert werden. Die erzielten Konvergenzergebnisse bestätigen die charakteristischen Leistungsmerkmale genetischer Algorithmen und stellen ein wichtiges Argument für die Verwendung dieser Methodik für komplexe finanzmarkttheoretische Problemtopologien dar (Abschnitt 2). Dennoch spielt insbesondere die Kombination zwischen Populationsgrösse und Generationenzahl eine wesentliche Rolle für die Effektivität und Effizienz genetischer Algorithmen. Ist eine Population zu klein, beinhaltet sie ein eher limitiertes genetisches Material bzw. Mass an Informationen. Im Ergebnis verhalten sich auch bei einer hohen Generationenzahl durchgeführte Optimierungen instabil. Die Resultate werden hinsichtlich der Approximation globaler Extrema unzuverlässig, da eine valide Replizierbarkeit bei einer hohen Volatilität der Ergebnisse ausgeschlossen ist. Auch eine überproportionale Individuenstärke bei einer sehr restriktiven Generationenzahl ist nicht zielführend, da dies zu einer äusserst breiten Suche im Lösungsraum führt und der Optimierungslauf abgebrochen wird, ohne dass eine hinreichende Konvergenz auf den Bereich des globalen Extremums erreicht wird. Bei solchen Konstellationen verharrt die Suche im Raum. Kombinationen sehr vieler Individuen in Verbindung mit einer grossen Generationenzahl lösen diese Probleme, sind aber mit hohem Rechenaufwand verbunden und ineffizient, da viele Optimierungsschritte durchgeführt werden, die keine nennenswerte Verbesserung der Approximation erbringen. Voruntersuchungen für diese Studie haben bestätigt, dass der genetische Algorithmus zunächst sehr schnell konvergiert, im weiteren Verlauf aber einen merklich abnehmenden Optimierungseffekt zeigt. Es konnte jedoch gezeigt werden, dass stabile und wiederholbare Ergebnisse aus den Optimierungen resultieren, welche über eine hinreichende Generationenzahl hinweg konstant bleiben. Damit lässt sich bestätigen, dass der genetische

Algorithmus einerseits in den Bereich des globalen Optimum konvergiert und die Approximationsgüte ein ausreichendes Mass erreicht hat.

Die optimale Kombination aus Generationenzahl und Populationsgrösse ist dabei für jede Gesamtsuchraumkonzeption individuell zu identifizieren. Im Zusammenhang mit dieser Studie wurden diverse Untersuchungen hinsichtlich des Konvergenzverhaltens des verwendeten genetischen Algorithmus und seinem Verhalten in der gegebenen Problemtopologie unternommen. Eine Elitest Reinsertion in Verbindung mit einer Kombination aus 2300 Individuen bei einer Generationenzahl von 200 hat sich dabei als günstig hinsichtlich der erzielten Ergebnisse, ihrer Stabilität und Replizierbarkeit erwiesen. Auch bei einer massiv erhöhten Populationsgrösse in Verbindung mit einer hohen Anzahl an Generationen konnten keine superioren Ergebnisse erreicht werden. Grafik 6 zeigt das Konvergenzverhalten des Algorithmus in Abhängigkeit der Anzahl Generationen anhand der Gesamt-Outperformance auf Basis eines 10-Jahres Datensatzes von 1980 bis 1989. Dieses exemplativ dargestellte Konvergenzverhalten ist auch für andere Optimierungen in dieser Studie repräsentativ. Es ist zunächst die rasche, für genetische Algorithmen typische Konvergenz zum globalen Maximum zu erkennen, welche im Verlauf an Geschwindigkeit verliert und schliesslich ganz abflacht. Ein Elitest Ersetzungs-schemata in Verbindung mit der oben genannten Generationenzahl hat sich als genügend herausgestellt, um sich im stabilen Teil der Optimierung wiederzufinden. Gleiches gilt für den Informationsgehalt der gewählten Populationsgrösse, welche genügend genetisches Material enthielt, um ein stabiles Konvergenzverhalten auf hinreichendem Konfidenzniveau im Bereich des globalen Optimums zu gewährleisten.

Grafik 6: Repräsentatives Konvergenzverhalten der In-Sample-Optimierungen des Genetischen Algorithmus



4. STRATEGIEKONZEPT

Eine erfolgreiche Handelsstrategie ist einerseits generell anwendbar und liefert andererseits eine Überschussrendite. Zwar kommt mit genetischen Algorithmen ein allgemeines und universell anwendbares Verfahren zum Einsatz, doch hängt ein resultierender Markterfolg nur zum Teil von der Arbeitsweise dieser Methodengruppe ab. So muss die zu identifizierende Handlungsanweisung Bestandteil des Suchraumes sein, den der genetische Algorithmus durchforscht. Das wesentliche Element einer konkreten Anwendung ist somit die Konzeption des Suchraumes und eines Bewertungskriteriums, dessen Maximum auch tatsächlich den gesuchten Zielgrößen entspricht. Weiter stellt die sich aus einer Strategie ergebende Handlungsvorgabe den Ansatzpunkt der Bewertungs- bzw. Fitnessfunktion dar, anhand dessen der Algorithmus die Güte resp. Rekombinationswahrscheinlichkeit der jeweiligen Lösungen ableitet. Da der genetische Algorithmus im Rahmen seiner Operatoren letztlich Permutationen binärer Vektoren erzeugt, muss sich das Strategiekonzept eindeutig in dieser Form repräsentieren lassen. Die Bewertungs- bzw. Fitnessfunktion stellt damit ausserdem die Verbindung zwischen Optimierungsverfahren und individueller Problemstellung dar. Sie ist daher für den Erfolg einer Anwendung zentral.

Die Motivation für den Einsatz genetischer Algorithmen liegt darin, mit aktiven Strategien für beliebige Zeitperioden eine Outperformance zu erzielen. Ein generelles Outperformen des Benchmarks setzt dabei Strategievariablen voraus, welche zeitstabil und signifikant einen Einfluss bzw. Erklärungsgehalt auf die untersuchten Zielgrößen haben. Diverse Untersuchungen haben gezeigt, dass ökonomischen und makroökonomischen Größen wie Zinsspreads, Defaultspreads, Dividendenrenditen aber auch Inflationsraten und Wachstumsindikatoren eine antizipative Wirkung hinsichtlich der konjunkturellen Entwicklung und damit der Erwartungsbildung am Aktienmarkt zugeschrieben werden kann (z. B. BAUER, JR. und LIEPINS, 1992; PESARAN und TIMMERMAN, 1995; OLSON und MOSSMAN, 2001). Das nachfolgend beschriebene Strategieggerüst spannt einen binär codierbaren Raum auf, in welchem die Summe aller Permutationen der zur Verfügung stehenden Bitpositionen eindeutig interpretierbar der Summe aller Strategievarianten entspricht. Dabei sollen Investitionsentscheidungen für zwei Asset-Klassen aufgrund von Ausprägungen je fünf ökonomischer Variablen getroffen werden, um eine Outperformance durch Markttiming im Vergleich zu einer Buy-and-Hold Strategie zu erzielen. Handlungsanweisungen fallen dabei jeweils 100% zu 0% für die betreffende Asset-Klasse aus, was zu einer zwar eher drastischen Allokationsentscheidung führt, die jedoch erhebliche Ertragspotentiale aufweist. Der Strategierahmen lautet damit generell:

WENN die ökonomische Variable A KLEINER ALS (GRÖSSER ALS) V, UND (ODER) die ökonomische Variable B KLEINER ALS (GRÖSSER ALS) W, UND (ODER) die ökonomische Variable C KLEINER ALS (GRÖSSER ALS) X, UND (ODER) die ökonomische Variable D KLEINER ALS (GRÖSSER ALS) Y, UND (ODER) die ökonomische Variable E KLEINER ALS (GRÖSSER ALS) Z, DANN investiere in Assetclass 1, ANSONSTEN investiere in die Assetclass 2.

Die Parameter V, W, X, Y und Z repräsentieren feststehende Schwellenwerte der Variablen A, B, C, D und E , die in 16 bzw. 8 diskrete Klassen eingeteilt sind. Dazu werden die Differenzen der jeweils höchsten bzw. tiefsten Variablenwerte durch 16 bzw. 8 geteilt, bevor die jeweiligen Variablenschwellen anhand der zuvor errechneten Intervallspannen festgelegt werden. Die je 16 bzw. 8 Klassen können exakt mit je 4 bzw. 3 Bits codiert werden, so dass eine eindeutige Zuordnung der Schwellen für jede Variable möglich wird. Um alle Klassen für alle Variablen eindeutig codieren zu können, sind insgesamt also 19 Bits erforderlich, wobei die ersten 4 den Schwellenwert der Variable A , die zweiten 4 den der Variable B , die dritten 4 Bits jenen der Variable C , die vierten 4 den der Variable D und die letzten 3 denjenigen der Variable E festlegen. Grafik 7 veranschaulicht die Idee.

Grafik 7: Beispiel zur Berechnung der Variablenschwellen

Fluktuation Variable A: 5, 18–10, 49						
Fluktuation Variable B: 52–72						
Fluktuation Variable C: 120–200						
Fluktuation Variable D: 85–130						
Fluktuation Variable E: 190–260						
Intervallspanne Variable A: $0,332 = (5,31/16)$						
Intervallspanne Variable B: $1,250 = (20/16)$						
Intervallspanne Variable C: $5,000 = (80/16)$						
Intervallspanne Variable D: $2,813 = (45/16)$						
Intervallspanne Variable E: $8,750 = (70/8)$						
Intervallschwellen:	Variable A	Variable B	Variable C	Variable D	Variable E	
(0000)	0	5,512	53,250	125,000	87,813	198,750
(0001)	1	5,844	54,500	130,000	90,626	207,500
(0010)	2	6,176	55,750	135,000	93,439	216,250
etc.						
(1111)	16	10,490	72,000	200,000	130,000	
Entsprechendes gilt für die Intervallschwellen der Variable E (hier nicht dargestellt)						

Zwischen den einzelnen Entscheidungsparametern existieren jeweils “und-“ bzw. “oder-“ Verknüpfungen. Jede der vier Bedingungen kann dabei unabhängig zutreffen oder nicht zutreffen. Daraus ergeben sich 16 verschiedene logische Gruppierungsmöglichkeiten, die mit 4 zusätzlichen Bits eindeutig binär codiert werden können. Ist das erste dieser Bits 0 (1), so ist der Operator zwischen Variable A und B OR (AND). Ist das zweite Bit 0 (1), so ist der Operator zwischen Variable B und C OR (AND). Für die Verknüpfungen der Variablen C mit D und D mit E gilt entsprechendes. Die Gruppierungsmöglichkeiten sind in Grafik 8 dargestellt.

Grafik 8: Beispiel zur und/oder Verknüpfung der Variablen

1)	0 0 0 0 :	A OR B OR C OR D OR E
2)	0 0 0 1 :	A OR B OR C OR D AND E
3)	0 0 1 0 :	A OR B OR C AND D OR E
4)	0 0 1 1 :	A OR B OR C AND D AND E
5)	0 1 0 0 :	A OR B AND C OR D OR E
6)	0 1 0 1 :	A OR B AND C OR D AND E
7)	0 1 1 0 :	A OR B AND C AND D OR E
8)	0 1 1 1 :	A OR B AND C AND D AND E
9)	1 0 0 0 :	A AND B OR C OR D OR E
10)	1 0 0 1 :	A AND B OR C OR D AND E
11)	1 0 1 0 :	A AND B OR C AND D OR E
12)	1 0 1 1 :	A AND B OR C AND D AND E
13)	1 1 0 0 :	A AND B AND C OR D OR E
14)	1 1 0 1 :	A AND B AND C OR D AND E
15)	1 1 1 0 :	A AND B AND C AND D OR E
16)	1 1 1 1 :	A AND B AND C AND D AND E

Jede Entscheidungsvariable kann mit ihrem zugehörigen Schwellenwert in einer “größer als” oder “kleiner als” Beziehung stehen. Um diese zwei Zustände für alle fünf Variablen eindeutig binär codierbar zu gewährleisten, sind weitere 5 Bits erforderlich. Das erste dieser Bits bestimmt, ob, um in die Assetclass 1 zu investieren, Variable *A* grösser (0) oder kleiner (1) als der zugehörige Schwellenwert *V* ist. Ist das zweite Bit 0 (1), so muss Variable *B* grösser (0) bzw. kleiner (1) *W* sein, damit in die Assetclass 1 investiert wird. Das gleiche gilt für die Variablen *C*, *D* und *E* und ihren zugehörigen Schwellenwerten *X*, *Y* und *Z*, woraus sich das in Grafik 9 dargestellte Konzept für die daraus entstehenden 32 Möglichkeiten ergibt.

Bit 1 bis 4, 5 bis 8, 9 bis 12, 13 bis 16 und 17 bis 19 codieren somit die diskreten Schwellenwerte *V*, *W*, *X*, *Y*, *Z* der Variablen *A*, *B*, *C*, *D* und *E*, Bit 20 bis 23 die Art der Verknüpfungen (AND/OR) zwischen den fünf Strategieparametern und Bit 24 bis 28 legt fest, ob die Variablenwerte der Parameter *A*, *B*, *C*, *D*, *E* jeweils grösser oder kleiner *V*, *W*, *X*, *Y* und *Z* sein müssen, um ein Investment in die erste Assetclass festzuschreiben. Eine Lösung besteht somit aus 28 Bits. Jeder Bitstring repräsentiert genau eine bestimmte fundamental basierte Timing-Strategievariation im Rahmen der definierten Restriktionen. Aus diesem Gerüst ergibt sich durch die Summe der Permutationen der Bitstrings ein Gesamtsuchraum möglicher Handelsstrategien von genau 2^{28} bzw. $16 * 16 * 16 * 16 * 8 * 16 * 32 = 268435456$. Die im Rahmen der verwendeten Parametersettings gerechneten 460000 Strategievarianten pro Optimierungslauf entsprechen damit jeweils ca. 0,17 % des Gesamtsuchraumes. Nachfolgendes Beispiel eines beliebig gewählten Bitstrings verdeutlicht, wie ein aus dem Optimierungsverlauf resultierender binär codierter String in eine Handelsstrategie decodiert werden kann:

1 1 1 0 0 1 1 0 1 0 0 0 0 1 0 1 1 0 0 0 0 1 1 1 1 0 0 1 ergibt demnach:

WENN die ökonomische Variable *A* KLEINER ALS 14, ODER die ökonomische Variable *B* KLEINER ALS 6, ODER die ökonomische Variable *C* GRÖßER ALS 8, UND die ökonomische Variable *D* GRÖßER ALS 5, UND die ökonomische Variable *E* KLEINER ALS 4, DANN investiere in die Assetclass 1, SONST investiere in die Assetclass 2.

Wobei *A, B, C, D, E* festgelegt, Assetclass 1 und 2 bestimmt und den Schwellenwerten 14, 6, 8, 5 sowie 4 für die jeweilige Variable ein konkreter Wert zugeordnet ist. Die Aufgabe des Algorithmus ist es nun, im Rahmen des Bewertungskonzeptes auf eine effiziente Art, die beste als Binärstring codierte Strategie zu identifizieren.

Grafik 9: Beispiel zur grösser/kleiner Verknüpfung der Variablen

1)	0 0 0 0 0	bestimmt	$A > V; B > W; C > X; D > Y; E > Z$	um in Assetclass 1 zu investieren
2)	0 0 0 0 1	bestimmt	$A > V; B > W; C > X; D > Y; E < Z$	um in Assetclass 1 zu investieren
3)	0 0 0 1 0	bestimmt	$A > V; B > W; C > X; D < Y; E > Z$	um in Assetclass 1 zu investieren
4)	0 0 0 1 1	bestimmt	$A > V; B > W; C > X; D < Y; E < Z$	um in Assetclass 1 zu investieren
5)	0 0 1 0 0	bestimmt	$A > V; B > W; C < X; D > Y; E > Z$	um in Assetclass 1 zu investieren
6)	0 0 1 0 1	bestimmt	$A > V; B > W; C < X; D > Y; E < Z$	um in Assetclass 1 zu investieren
7)	0 0 1 1 0	bestimmt	$A > V; B > W; C < X; D < Y; E > Z$	um in Assetclass 1 zu investieren
8)	0 0 1 1 1	bestimmt	$A > V; B > W; C < X; D < Y; E < Z$	um in Assetclass 1 zu investieren
9)	0 1 0 0 0	bestimmt	$A > V; B < W; C > X; D > Y; E > Z$	um in Assetclass 1 zu investieren
10)	0 1 0 0 1	bestimmt	$A > V; B < W; C > X; D > Y; E < Z$	um in Assetclass 1 zu investieren
11)	0 1 0 1 0	bestimmt	$A > V; B < W; C > X; D < Y; E > Z$	um in Assetclass 1 zu investieren
12)	0 1 0 1 1	bestimmt	$A > V; B < W; C > X; D < Y; E < Z$	um in Assetclass 1 zu investieren
13)	0 1 1 0 0	bestimmt	$A > V; B < W; C < X; D > Y; E > Z$	um in Assetclass 1 zu investieren
14)	0 1 1 0 1	bestimmt	$A > V; B < W; C < X; D > Y; E < Z$	um in Assetclass 1 zu investieren
15)	0 1 1 1 0	bestimmt	$A > V; B < W; C < X; D < Y; E > Z$	um in Assetclass 1 zu investieren
16)	0 1 1 1 1	bestimmt	$A > V; B < W; C < X; D < Y; E < Z$	um in Assetclass 1 zu investieren
17)	1 0 0 0 0	bestimmt	$A < V; B > W; C > X; D > Y; E > Z$	um in Assetclass 1 zu investieren
18)	1 0 0 0 1	bestimmt	$A < V; B > W; C > X; D > Y; E < Z$	um in Assetclass 1 zu investieren
19)	1 0 0 1 0	bestimmt	$A < V; B > W; C > X; D < Y; E > Z$	um in Assetclass 1 zu investieren
20)	1 0 0 1 1	bestimmt	$A < V; B > W; C > X; D < Y; E < Z$	um in Assetclass 1 zu investieren
21)	1 0 1 0 0	bestimmt	$A < V; B > W; C < X; D > Y; E > Z$	um in Assetclass 1 zu investieren
22)	1 0 1 0 1	bestimmt	$A < V; B > W; C < X; D > Y; E < Z$	um in Assetclass 1 zu investieren
23)	1 0 1 1 0	bestimmt	$A < V; B > W; C < X; D < Y; E > Z$	um in Assetclass 1 zu investieren
24)	1 0 1 1 1	bestimmt	$A < V; B > W; C < X; D < Y; E < Z$	um in Assetclass 1 zu investieren
25)	1 1 0 0 0	bestimmt	$A < V; B < W; C > X; D > Y; E > Z$	um in Assetclass 1 zu investieren
26)	1 1 0 0 1	bestimmt	$A < V; B < W; C > X; D > Y; E < Z$	um in Assetclass 1 zu investieren
27)	1 1 0 1 0	bestimmt	$A < V; B < W; C > X; D < Y; E > Z$	um in Assetclass 1 zu investieren
28)	1 1 0 1 1	bestimmt	$A < V; B < W; C > X; D < Y; E < Z$	um in Assetclass 1 zu investieren
29)	1 1 1 0 0	bestimmt	$A < V; B < W; C < X; D > Y; E > Z$	um in Assetclass 1 zu investieren
30)	1 1 1 0 1	bestimmt	$A < V; B < W; C < X; D > Y; E < Z$	um in Assetclass 1 zu investieren
31)	1 1 1 1 0	bestimmt	$A < V; B < W; C < X; D < Y; E > Z$	um in Assetclass 1 zu investieren
32)	1 1 1 1 1	bestimmt	$A < V; B < W; C < X; D < Y; E < Z$	um in Assetclass 1 zu investieren

5. BEWERTUNGSKONZEPT

Der Algorithmus soll aus dem Gesamtsuchraum die “beste” Strategie herausuchen. Das Kriterium dazu kommt über die Bewertungs- und Fitnessfunktion zum Ausdruck, die jedoch gleichzeitig das Strategieziel verkörpern muss. Gemäss obigen Konzeptes existieren zwei Anlageklassen, wobei entweder in die eine oder in die jeweils andere investiert werden kann. Aufgrund der Variablen, ihrer zugehörigen Schwellenwerte sowie den logischen Verknüpfungen ist also für jedes Zeitintervall eindeutig festzustellen, ob ein (100%) Investment in Assetclass 1 oder 2 zu erfolgen hat. Als Bewertungs- resp. Fitnessmass dient hierbei die Überschussrendite über eine Buy-and-Hold Strategie als Benchmark. Besteht die Benchmarkinvestition aus einer der Asset-Klassen und stellt diese eine risikobehaftete Anlage, die für die Timingstrategie alternative Anlageklasse jedoch ein risikofreies Kapitalmarktinstrument dar, so ist gewährleistet, dass die Volatilität der Timingstrategie stets gleich oder kleiner als die der Buy-and-Hold Strategie ist. Dies ist eine beim Vergleich der Optimierungsergebnisse wesentliche Überlegung. Die Überschussrendite ist somit das einzige Bewertungskriterium der Güte der verschiedenen Individuen. Die Rendite der Buy-and-Hold Strategie berechnet sich dabei aus der Summe der entsprechenden zeithorizontgerechten Renditen der relevanten Assetklasse über den betrachteten Zeitraum. Die Rendite der Timingstrategie ergibt sich aus der Addition der Teilsummen beider Asset-Klassen, die über das betrachtete Zeitintervall aus den Einzelsummen der jeweils wegen entsprechender Investitionsanweisungen relevanten zeithorizontgerechten Renditen der Asset-Klassen 1 oder 2 zu bilden ist. Die Überschussrendite bzw. Fitness errechnet sich dann aus der Differenz der Gesamtrenditen beider Strategievarianten. Das Bewertungskonzept kann anhand folgender Gleichungen dargestellt werden:

$$r_{ti\ min\ g} = \sum_{t=1}^T r_t * I_A(t) + \sum_{t=1}^T r_f(t) * I_B(t) \quad (3)$$

$$r_{buy-and-hold} = \sum_{t=1}^T r_t \quad (4)$$

$$\Delta r = r_{ti\ min\ g} - r_{buy-and-hold} \quad (5)$$

wobei

$$r_t = \ln P_t - \ln P_{t-1} \quad (6)$$

und

P_t dem Preis der Asset-Klasse 1 zum Zeitpunkt t entspricht.

Hierbei bezeichnet r_t die stetige zeithorizontgerechte Rendite der Asset-Klasse 1, T die Anzahl der Betrachtungsintervalle und $r_f(t)$ den (risikolosen) zeithorizontgerechten Zins der Asset-Klasse 2. $I_A(t)$ und $I_B(t)$ verkörpern Indikatorvariablen, wobei $I_A(t)$ im Falle einer Investitionsanweisung in Asset-Klasse 1 Eins, andernfalls Null ist. Gleiches gilt entsprechend für die Indikatorvariable $I_B(t)$. Über diese Variablen wird somit erreicht, dass pro Betrachtungszeitpunkt gemäss der anhand der jeweiligen Strategie zu treffenden Investitionsentscheidung stets der Renditebeitrag nur einer der beiden Asset-Klassen zur Bildung der Gesamrendite betreffender Timingstrategie Berücksichtigung findet.

Sowohl die Gestaltung des Suchraumes als auch die Bewertungsstrategie implizieren zugunsten der praktischen Umsetzbarkeit verschiedene Simplifikationen. So werden Investitionsentscheidungen im Rahmen des Strategiekonzeptes nur anhand von fünf ökonomischen Variablen getroffen, die, auch wenn sie einen guten Erklärungsgehalt bzgl. der Entwicklung der Assetklassen aufweisen, die Komplexität des Gesamtsystems wahrscheinlich nicht hinreichend abbilden. Weiter sind die Investitionsmöglichkeiten auf zwei Anlageklassen limitiert, was erheblichen Einfluss auf das Erfolgspotential der gewählten Strategie hat. Ausserdem können die Investitionsanteile aufgrund des verwendeten Bewertungskonzeptes nicht beliebig gewichtet werden. Da es nur möglich ist, in ein Asset ganz oder gar nicht zu investieren, sind Gewichtungskombinationen, die ein gleichzeitiges Investment in beide Assets zur Folge hätten, nicht möglich. Eine Investitionsentscheidung zugunsten einer der möglichen Assetklassen setzt zudem ein 100%iges Reinvestment über den gesamten Betrachtungszeitraum in die entsprechenden Klassen voraus, um die errechneten Gesamrenditen zu erreichen. Im Rahmen der Bewertungsfunktion dient als Gütemass und Bewertungskriterium ausschliesslich die Rendite. Zwar lassen sich Aussagen bzgl. der Performance einer Timingstrategie im Verhältnis zur entsprechenden Benchmarkstrategie bei der Beurteilung identifizierter Approximationen anstellen, doch ist im eigentlichen Bewertungskonzept weder die Berücksichtigung von Volatilitäten, Risikoaversionen noch anderer denkbarer Faktoren enthalten. Weiter wird von der Berücksichtigung etwaiger Transaktionskosten abgesehen. Zwar sind diese insbesondere für professionelle Investoren bzw. im Derivathandel eher tief, doch stellen sie v.a. bei hohen Wechselraten zwischen den Anlageklassen ein nennenswertes Faktum dar, welches eine allfällige errechnete Performance schmälern würde. Schliesslich sind sowohl im Strategie- als auch im Bewertungskonzept keine Leerverkäufe vorgesehen.

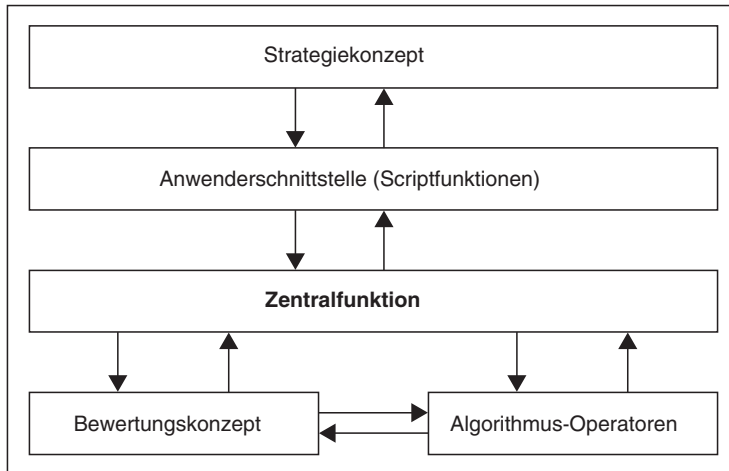
6. IMPLEMENTATION

Alle Optimierungen wurden mit einer modular und individuell konfigurierbaren Programmumgebung durchgeführt². Diese stellt diverse grundlegende Funktionen, Operatoren und Routinen zur Implementierung von genetischen Algorithmen zur Verfügung und ist in mehreren Schichten aufgebaut. Der Zugang erfolgt über eine Anwenderschnittstelle in der Form einer Skriptfunktion. Über diese Skriptfunktion werden alle der Anwendung zugrundeliegenden Operatoren und Parameter des genetischen Algorithmus zusammengestellt. Die Anwendungsschnittstelle dient weiter der Konfiguration des genetischen Algorithmus, um Strategie- und Bewertungskonzept als Rahmenbedingungen des zuvor konfigurierten Algorithmus in die durchzuführenden Rechenroutinen einzubeziehen. Damit wird über die Skriptfunktion als oberste Operationsebene der verwendeten Programmumgebung eine Verbindung zwischen der allgemeinen Methodik von Genetischen Algorithmen und der individuellen Konzeption des Untersuchungsziels hergestellt. Eine Zentralfunktion steuert alle relevanten genetischen Operatoren. Neben der Initialisierung der zuvor definierten internen Variablen und Strukturen erfolgt die Initialisierung der Population. Danach beginnt die Ausführung des genetischen Algorithmus mit der Durchführung der verschiedenen Routinen zur Selektion, Rekombination und Mutation. Der Vorteil der Benutzung dieser Programmumgebung liegt darin, dass alle nötigen Operatoren und Verfahren mit hinreichendem Variationspotential verfügbar und kombinierbar sind.

Grafik 10 verdeutlicht den Aufbau der verwendeten Programmumgebung und zeigt insbesondere die Zusammenhänge zwischen genetischem Algorithmus und der Implementierung des untersuchungsspezifischen Strategie- und Bewertungskonzeptes. Weiter wird die überragende Bedeutung von Strategie- und Bewertungskonzept deutlich. Diese realisieren die praktische Einsatzfähigkeit genetischer Algorithmen auf das in der Form eines Binärstrings codierte Untersuchungsziel. Während der Algorithmus im Rahmen der gewählten Parameter die zuvor initialisierten Binärstrings (Handlungsstrategien) "mischt", setzt das Strategiekonzept den ökonomischen, praxisrelevanten und interpretierbaren Rahmen einer möglichen Lösung fest. Die Bewertungsfunktion definiert dem genetischen Algorithmus das Optimierungskriterium, nach welchem die zu optimierenden Individuen vor den Berechnungsläufen zu selektieren sind. Nach Erreichen des Abbruchkriteriums liegt ein dem Bewertungskriterium entsprechend optimaler Lösungsstring vor, der eindeutig in eine Handlungsstrategie decodiert werden kann. Die für alle Optimierungsläufe verwendeten genetischen Algorithmuskonfigurationen sowie das implementierte Strategie- und Bewertungsmodell sind in den Abschnitten zur Methodik, der Strategie- und der Bewertungskonzeption (Abschnitte 2, 4 und 5) ausgeführt.

2. Alle Berechnungen wurden mit der Genetic and Evolutionary Algorithm Toolbox for use with Matlab Version 1.95 (POHLHEIM, 2000) durchgeführt.

Grafik 10: Implementation des Strategie- und Bewertungskonzeptes in den genetischen Algorithmus



7. DATEN

Sowohl die Daten der Anlageklassen als auch der Erklärungsvariablen erstrecken sich über den Zeitraum von 1980 bis 2000 und beruhen auf täglicher Basis. Die risikobehaftete Anlageklasse (Assetclass 1) wird durch die täglichen Renditen des S&P 500 Composite TotalReturn Index³ dargestellt. Als alternative, risikolose Anlageklasse (Assetclass 2) werden tägliche Renditen eines von Merrill Lynch lancierten 3-Monats T-Bill-Rate Indexes verwendet. Den Erklärungsvariablen *A*, *B*, *C*, *D* und *E* liegen ein Zinsspread, Defaultspread, eine Indexdividendenrendite, die Entwicklung des amerikanischen Bruttoinlandsproduktes sowie ein Preisindex je bezogen auf die USA zugrunde. Der Termspread wurde dabei als Zinsdifferenz eines 10 Jahres US-Benchmark Government Index sowie den zeitkongruenten Renditen der zweiten Assetclass gebildet. Der Defaultspread besteht aus den Renditedifferenzen eines Lehman Intermediate Credit Bond Index und einem US Total Government Index von Datastream mit jeweils vergleichbarer Macauley Duration. Die dritte Erklärungsvariable wird aus den zeithorizontgerechten Dividendenrenditen des als Assetclass 1 verwendeten S&P 500 Composite gebildet. Die Daten der vierten Erklärungsvariable basieren auf annualisierten und preisadjustierten relativen quartalsweisen Veränderungsrate zum Jahresdurchschnitt des amerikanischen Bruttoinlandsproduktes. Der Preisindex wird durch ein saisonbereinigtes repräsentatives Sample der jährlichen amerikanischen Inflationsraten dargestellt, deren relative Entwicklung die fünfte Erklärungsvariable darstellt.

3. Die Datenquelle für alle Daten ist Primark Datastream.

Die Resultate wurden rollierend aus Optimierungsperioden und anschließenden out-of-sample Anwendungszeiträumen gewonnen. Insgesamt wurden Tradingstrategien auf der Basis fünf und zehnjähriger in-sample Zeithorizonten identifiziert und auf darauffolgende ein- bzw. fünfjährige Datensätze angewendet. Wurde eine Strategie z. B. über einen Datensatz von 1980–1984 gefunden, so wurde sie anschliessend für das Jahr 1985 bzw. 1985–1989 angewendet. Anschliessend wurde über einen Optimierungszeitraum von 1981–1985 eine Strategie entwickelt, welche für die Zeiträume 1986 bzw. 1986–1990 angewendet wurde. Auf diese Weise konnten bis zum Jahre 2000 bei fünfjährigen Optimierungsperioden 16 Strategien bei einjähriger und 12 Strategien bei fünfjähriger Anwendungsdauer validiert werden. Bei analogem Vorgehen der 10-jährigen Optimierungszeiträume wurden nur einjährige Anwendungszeithorizonte gewählt, so dass dabei insgesamt 11 Strategien identifiziert und getestet werden konnten. Grundsätzlich wurde davon ausgegangen, dass die erfolgreichste in-sample Strategie den höchsten Erklärungsgehalt bzgl. des Bezugssystems aufweist. Daher wurden v.a. diese Strategien für spätere Anwendungen verwendet. Da jedoch die Approximationsschritte an das globale Optimum v.a. im späteren Verlauf einer Optimierung oft nur noch marginal sind, könnten auch weitere Lösungen im Näherungsbereich out-of-sample erfolgreich sein. Da die antizipative Wirkung einer Strategie a priori nicht sichergestellt sein kann, wurden z. T. auch Portfolios erfolgreicher Strategien aus dem Optimierungsverlauf gebildet, was einer Diversifikation über Investitionsanweisungen entspricht. Von den insgesamt rund 18 Millionen gerechneten Timingstrategien werden nachfolgend die im Rahmen der beschriebenen Grundsätze identifizierten 39 Lösungen dargestellt, analysiert und interpretiert.

8. ERGEBNISSE

Nachfolgende Tabellen zeigen die verschiedenen Ergebnisse, die mit der Anwendung des beschriebenen Methodensetup in der oben erläuterten Form erzielt wurden. Da mit Ausnahme eines Bewertungsparameters alle Auswertungen auf jährlicher Basis beruhen, können alle dargestellten Ergebnisse direkt miteinander verglichen werden. Tabelle 1 zeigt dabei die Resultate der in-sample-, out-of-sample und Benchmarkstrategien, die aus fünfjährigen Optimierungs- sowie fünfjährigen Anwendungszeiträumen erzielt wurden. Tabelle 2 zeigt analoge Ergebnisse für die über die Optimierungszeithorizonte identifizierten Lösungen, während die Anwendungsdauer nur ein Jahr betrug. Tabelle 3 zeigt den Erfolg anhand 10-jähriger Datensätze erzeugter Strategien, die auf einjährige Anschlusszeiträume angewendet wurden. Hierbei ist auf die Besonderheit hinzuweisen, dass die über 10-jährige Datensätze identifizierten Lösungen in-sample auf die zwar zugehörigen, jedoch zwei mal 5-jährigen Datensätze getestet wurden. Die gesamten in-sample Datensätze bestanden damit jeweils aus zwei Teilen, die zwar den 10-jahres Zeithorizont kongruent darstellten, jedoch in zwei 5-jährige Datenperioden aufgesplittet wurden. Die Unterbrechung des Gesamttestzeitraumes führt ipso facto zu

unterschiedlichen Schwellenwerten der Erklärungsvariablen in jedem der Subdatensätze. Im Vergleich zu den Resultaten der zugehörigen Optimierungsläufe mussten damit andere Ergebnisse auftreten, so dass es sich hierbei eher um in-sample Anwendungen im weiteren Sinne handelt. Tabelle 4 beinhaltet schliesslich auf den Werten der ersten drei Tabellen beruhende Aggregationen der Ergebnisse, welche die abgeleiteten Beobachtungen und Effekte verdeutlichen.

Für alle Ergebnisse wurde ein einheitliches Bewertungssetup gewählt. Der Parameter "Aktienanteil" gibt dabei die über die jeweilige Investitionsdauer durchschnittliche prozentuale Anlage in die risikobehaftete Investitionsklasse an. Die Grösse ist damit als ein Proxy für das mit der Umsetzung der betreffenden Strategie übernommene systematische Risiko anzusehen, was über die das Risiko berücksichtigenden Kennziffern auch zum Ausdruck kommt. Da als Benchmark eine passive Investitionsstrategie in die risikobehaftete Anlageklasse gewählt wurde, ist deren Aktienanteil stets bei 100 %.

Die prozentualen Trefferquoten zeigen den Anteil richtig getroffener Investitionsentscheidungen im Verhältnis zu den jeweils gesamt existierenden Datensätzen einer Periode an. Eine Entscheidung wurde dann als "richtig" qualifiziert, wenn die durch sie erzielte Rendite gleich oder grösser als die vergleichbare Rendite der alternativen Assetklasse war. Selbstverständlich ist diese Grösse auch für die Buy-and-Hold Strategien a priori nicht vorhersagbar, obwohl hierbei Quoten im nahen Bereich von 50 % aufgrund der Hypothese eines bei Aktienkursen zu beobachtenden Random-Walk Verhaltens nicht überraschend sind. Bei diesem Parameter ist jedoch zu betonen, dass hohe Trefferquoten grundsätzlich auch mit guten Prognoseergebnissen bzw. Performanceergebnissen einhergehen sollten, hier jedoch keine kausale Notwendigkeit besteht. Vielmehr ist es denkbar, auch mit sehr tiefen bzw. hohen Trefferquoten sehr gute resp. besonders schlechte Resultate zu erzielen, da jeweils nur gemessen wurde, ob eine Investitionsanweisung richtig, nicht aber, welcher Ausprägung die damit zu erzielende Rendite war. Trefferquoten sind damit nur ein relativ grobes Gütekriterium, wenn z. B. prozentual viele richtige Entscheidungen getroffen werden, die jedoch ausschliesslich in Phasen tiefer Renditen fallen, während bei hohen möglichen Renditen das falsche Asset gewählt wird. Gleiches gilt analog für mögliche tiefe Trefferquoten im Zusammenhang mit guten Renditeergebnissen. Da hinter hohen bzw. tiefen Renditen unterschiedlich hohe Volatilitäten stecken, ist auch die Trefferquote nur im Zusammenhang mit anderen Gütekriterien zu sehen. Beide bislang beschriebenen Parameter wurden als insensitiv bezüglich des Investitionszeithorizontes betrachtet. Damit wird ihre Vergleichbarkeit in Bezug auf verschiedene Anlageperioden auch ohne weitere Standardisierung unterstellt.

Tabelle 1: Ergebnisse 5 Jahre Optimierung / 5 Jahre Anwendung

	Aktienanteil in %	Trefferquote in %	Anzahl Switches	Gesamt- rendite p.a. in %	Performance p.a. in %	Anteilige Volatilität p.a. in %	Tatsächliche Volatilität p.a. in %	Rendite/ Risiko Ratio p.a.	Sharpe Ratio p.a.
Strategie In-Sample 1980–1984	55	55	88	28.83	14.99	9.74	13.72	2.10	1.28
Benchmark- strategie	100	47	0	13.84	0	17.71	17.71	0.78	0.13
Strategie Out- Of-Sample 1985–1989	62	56	69	27.53	8.99	14.29	15.84	1.74	1.35
Benchmark- strategie	100	53	0	18.55	0	23.04	23.04	0.81	0.54
Strategie In-Sample 1981–1985	55	56	59	28.01	14.29	8.96	12.24	2.29	1.44
Benchmark- strategie	100	47	0	13.72	0	16.29	16.29	0.84	0.20
Strategie Out- Of-Sample 1986–1990	24	48	3	10.07	-2.32	5.75	8.52	1.18	0.50
Benchmark- strategie	100	53	0	12.34	0	23.97	23.97	0.51	0.28
Strategie In-Sample 1982–1986	61	56	68	31.16	13.01	10.11	13.05	2.39	1.72
Benchmark- strategie	100	48	0	18.15	0	16.57	16.57	1.10	0.57
Strategie Out- Of-Sample 1987–1991	31	52	39	18.79	4.51	7.41	10.18	1.85	1.29
Benchmark- strategie	100	52	0	14.28	0	23.89	23.89	0.60	0.36
Strategie In-Sample 1983–1987	53	58	80	31.94	16.69	11.42	15.36	2.08	1.58
Benchmark- strategie	100	51	0	15.25	0	22.29	22.29	0.68	0.34
Strategie Out- Of-Sample 1988–1992	52	53	51	19.20	4.46	8.75	13.00	1.48	1.08
Benchmark- strategie	100	52	0	14.74	0	16.82	16.82	0.88	0.57
Strategie In-Sample 1984–1988	65	57	75	31.05	16.8	14.94	17.00	1.83	1.41
Benchmark- strategie	100	51	0	14.25	0	22.99	22.99	0.62	0.31
Strategie Out- Of-Sample 1989–1993	96	53	11	13.84	0.25	14.31	14.65	0.94	0.62
Benchmark- strategie	100	51	0	13.59	0	14.91	14.91	0.91	0.60
Strategie In-Sample 1985–1989	80	56	54	32.47	13.93	18.43	17.11	1.90	1.54
Benchmark- strategie	100	53	0	18.55	0	23.04	23.04	0.81	0.54
Strategie Out- Of-Sample 1990–1994	83	52	9	8.97	0.63	11.78	12.66	0.71	0.37
Benchmark- strategie	100	50	0	8.34	0	14.19	14.19	0.59	0.28

	Aktienanteil in %	Trefferquote in %	Anzahl Switches	Gesamt- rendite p.a. in %	Performance p.a. in %	Anteilige Volatilität p.a. in %	Tatsächliche Volatilität p.a. in %	Rendite/ Risiko Ratio p.a.	Sharpe Ratio p.a.
Strategie In-Sample 1986–1990	79	56	65	30.47	18.08	18.94	17.61	1.73	1.40
Benchmark- strategie	100	53	0	12.39	0	23.97	23.97	0.52	0.28
Strategie Out- Of-Sample 1991–1995	93	54	10	14.21	-1.15	11.27	11.48	1.24	0.86
Benchmark- strategie	100	51	0	15.35	0	12.12	12.12	1.27	0.91
Strategie In-Sample 1987–1991	71	56	80	32.51	18.23	16.96	17.19	1.89	1.56
Benchmark- strategie	100	52	0	14.28	0	23.89	23.89	0.60	0.36
Strategie Out- Of-Sample 1992–1996	74	52	49	7.96	-6.2	8.41	9.77	0.81	0.37
Benchmark- strategie	100	52	0	14.16	0	11.36	11.36	1.25	0.87
Strategie In-Sample 1988–1992	76	55	56	24.41	9.67	12.79	13.72	1.78	1.40
Benchmark- strategie	100	52	0	14.74	0	16.82	16.82	0.88	0.57
Strategie Out- Of-Sample 1993–1997	85	54	40	17.09	-1.36	11.86	12.69	1.35	0.99
Benchmark- strategie	100	53	0	18.44	0	13.95	13.95	1.32	0.99
Strategie In-Sample 1989–1993	80	55	50	21.70	8.1	11.92	12.25	1.77	1.39
Benchmark- strategie	100	51	0	13.59	0	14.91	14.91	0.91	0.60
Strategie Out- Of-Sample 1994–1998	37	50	23	14.33	-7.22	6.28	11.65	1.23	0.80
Benchmark- strategie	100	53	0	21.55	0	16.98	16.98	1.27	0.98
Strategie In-Sample 1990–1994	85	54	36	15.31	6.97	12.07	12.42	1.23	0.88
Benchmark- strategie	100	50	0	8.34	0	14.19	14.19	0.59	0.28
Strategie Out- Of-Sample 1995–1999	45	49	15	14.69	-10.43	8.43	13.63	1.08	0.71
Benchmark- strategie	100	53	0	25.12	0	18.72	18.72	1.34	1.07
Strategie In-Sample 1991–1995	80	55	55	20.32	4.97	9.70	10.67	1.90	1.50
Benchmark- strategie	100	51	0	15.35	0	12.12	12.12	1.27	0.91
Strategie Out- Of-Sample 1996–2000	95	51	6	17.90	1.07	20.60	20.33	0.88	0.63
Benchmark- strategie	100	50	0	16.82	0	21.68	21.68	0.78	0.54

Tabelle 2: Ergebnisse 5 Jahre Optimierung / 1 Jahr Anwendung

	Aktienanteil in %	Trefferquote in %	Anzahl Switches	Gesamt- rendite p.a. in %	Performance p.a. in %	Anteilige Volatilität p.a. in %	Tatsächliche Volatilität p.a. in %	Rendite/ Risiko Ratio p.a.	Sharpe Ratio p.a.
Strategie In-Sample 1980–1984	55	55	88	28.83	14.99	9.74	13.72	2.10	1.28
Benchmark- strategie	100	47	0	13.84	0.00	17.71	17.71	0.78	0.13
Strategie Out- Of-Sample 1985	70	52	17	21.75	–5.89	8.36	9.85	2.21	1.43
Benchmark- strategie	100	52	0	27.64	0.00	11.94	11.94	2.31	1.67
Strategie In-Sample 1981–1985	55	56	59	28.01	14.29	8.96	12.24	2.29	1.44
Benchmark- strategie	100	47	0	13.72	0.00	16.29	16.29	0.84	0.20
Strategie Out- Of-Sample 1986	56	51	9	16.13	–0.70	9.73	12.10	1.33	0.86
Benchmark- strategie	100	52	0	17.13	0.00	17.38	17.38	0.99	0.64
Strategie In-Sample 1982–1986	61	56	68	31.16	13.01	10.11	13.05	2.39	1.72
Benchmark- strategie	100	48	0	18.15	0.00	16.57	16.57	1.10	0.57
Strategie Out- Of-Sample 1987	28	51	1	24.05	18.96	11.01	9.68	2.48	1.87
Benchmark- strategie	100	54	0	5.09	0.00	39.64	39.64	0.13	–0.02
Strategie In-Sample 1983–1987	53	58	80	31.94	16.69	11.42	15.36	2.08	1.58
Benchmark- strategie	100	51	0	15.25	0.00	22.29	22.29	0.68	0.34
Strategie Out- Of-Sample 1988	44	52	15	20.32	4.98	8.89	13.64	1.49	1.08
Benchmark- strategie	100	52	0	15.34	0.00	20.20	20.20	0.76	0.51
Strategie In-Sample 1984–1988	65	57	75	31.05	16.80	14.94	17.00	1.83	1.41
Benchmark- strategie	100	51	0	14.25	0.00	22.99	22.99	0.62	0.31
Strategie Out- Of-Sample 1989	82	58	6	28.99	1.44	12.68	14.29	2.03	1.63
Benchmark- strategie	100	57	0	27.55	0.00	15.46	15.46	1.78	1.41
Strategie In-Sample 1985–1989	80	56	54	32.47	13.93	18.43	17.11	1.90	1.54
Benchmark- strategie	100	53	0	18.55	0.00	23.04	23.04	0.81	0.54
Strategie Out- Of-Sample 1990	92	53	12	1.52	4.69	17.45	18.11	0.08	–0.23
Benchmark- strategie	100	52	0	–3.17	0.00	18.97	18.97	–0.17	–0.47

	Aktienanteil in %	Trefferquote in %	Anzahl Switches	Gesamt- rendite p.a. in %	Performance p.a. in %	Anteilige Volatilität p.a. in %	Tatsächliche Volatilität p.a. in %	Rendite/ Risiko Ratio p.a.	Sharpe Ratio p.a.
Strategie In-Sample 1986–1990	79	56	65	30.47	18.08	18.94	17.61	1.73	1.40
Benchmark- strategie	100	53	0	12.39	0.00	23.97	23.97	0.52	0.28
Strategie Out- Of-Sample 1991	73	48	17	13.42	-13.20	12.28	13.09	1.03	0.61
Benchmark- strategie	100	48	0	26.62	0.00	16.82	16.82	1.58	1.26
Strategie In-Sample 1987–1991	71	56	80	32.51	18.23	16.96	17.19	1.89	1.56
Benchmark- strategie	100	52	0	14.28	0.00	23.89	23.89	0.60	0.36
Strategie Out- Of-Sample 1992	71	54	16	3.05	-4.23	8.09	9.66	0.32	-0.04
Benchmark- strategie	100	50	0	7.37	0.00	11.40	11.40	0.65	0.35
Strategie In-Sample 1988–1992	76	55	56	24.41	9.67	12.79	13.72	1.78	1.40
Benchmark- strategie	100	52	0	14.74	0.00	16.82	16.82	0.88	0.57
Strategie Out- Of-Sample 1993	76	53	16	12.03	2.43	7.70	7.91	1.52	1.15
Benchmark- strategie	100	50	0	9.60	0.00	10.13	10.13	0.95	0.66
Strategie In-Sample 1989–1993	80	55	50	21.70	8.10	11.92	12.25	1.77	1.39
Benchmark- strategie	100	51	0	13.59	0.00	14.91	14.91	0.91	0.60
Strategie Out- Of-Sample 1994	83	50	7	-0.44	-1.70	9.66	10.79	-0.04	-0.43
Benchmark- strategie	100	50	0	1.26	0.00	11.64	11.64	0.11	-0.26
Strategie In-Sample 1990–1994	85	54	36	15.31	6.97	12.07	12.42	1.23	0.88
Benchmark- strategie	100	50	0	8.34	0.00	14.19	14.19	0.59	0.28
Strategie Out- Of-Sample 1995	82	58	20	29.39	-2.52	7.60	8.55	3.44	2.79
Benchmark- strategie	100	58	0	31.91	0.00	9.27	9.27	3.44	2.84
Strategie In-Sample 1991–1995	80	55	55	20.32	4.97	9.70	10.67	1.90	1.50
Benchmark- strategie	100	51	0	15.35	0.00	12.12	12.12	1.27	0.91
Strategie Out- Of-Sample 1996	94	51	1	19.15	-1.51	13.20	13.39	1.43	1.05
Benchmark- strategie	100	51	0	20.66	0.00	13.89	13.89	1.49	1.12

	Aktienanteil in %	Trefferquote in %	Anzahl Switches	Gesamt- rendite p.a. in %	Performance p.a. in %	Anteilige Volatilität p.a. in %	Tatsächliche Volatilität p.a. in %	Rendite/ Risiko Ratio p.a.	Sharpe Ratio p.a.
Strategie In-Sample 1992–1996	86	56	68	18.97	4.81	9.76	10.19	1.86	1.44
Benchmark- strategie	100	52	0	14.16	0.00	11.36	11.36	1.25	0.87
Strategie Out- Of-Sample 1997	30	51	6	22.52	-6.62	6.42	10.97	2.05	1.58
Benchmark- strategie	100	53	0	28.78	0.00	21.41	21.41	1.34	1.10
Strategie In-Sample 1993–1997	89	55	18	22.37	3.93	12.41	12.83	1.74	1.38
Benchmark- strategie	100	53	0	18.44	0.00	13.95	13.95	1.32	0.99
Strategie Out- Of-Sample 1998	98	54	2	22.06	-3.07	23.42	23.74	0.93	0.72
Benchmark- strategie	100	54	0	25.13	0.00	23.90	23.90	1.05	0.85
Strategie In-Sample 1994–1998	59	56	55	29.29	7.74	10.02	12.28	2.39	1.98
Benchmark- strategie	100	53	0	21.55	0.00	16.98	16.98	1.27	0.97
Strategie Out- Of-Sample 1999	41	50	3	15.91	-3.19	8.69	14.24	1.12	0.79
Benchmark- strategie	100	49	0	19.10	0.00	21.20	21.20	0.90	0.68
Strategie In-Sample 1995–1999	91	55	28	30.48	5.37	17.04	17.30	1.76	1.47
Benchmark- strategie	100	53	0	25.12	0.00	18.72	18.72	1.34	1.07
Strategie Out- Of-Sample 2000	100	46	0	-9.54	0.00	26.22	26.22	-0.36	-0.59
Benchmark- strategie	100	46	0	-9.54	0.00	26.22	26.22	-0.36	-0.59

Tabelle 3: Ergebnisse 10 Jahre Optimierung / 1 Jahr Anwendung

	Aktienanteil in %	Trefferquote in %	Anzahl Switches	Gesamt- rendite p.a. in %	Performance p.a. in %	Anteilige Volatilität p.a. in %	Tatsächliche Volatilität p.a. in %	Rendite/ Risiko Ratio p.a.	Sharpe Ratio p.a.
Strategie In-Sample 1980–1984 & 1985–1989	58	47	160	25.66	9.47	11.91	14.69	1.75	1.15
Benchmark- strategie	100	50	0	16.19	0	20.54	20.54	0.79	0.36
Strategie Out- Of-Sample 1990	61	55	27	14.21	17.38	10.43	11.36	1.25	0.75
Benchmark- strategie	100	52	0	-3.17	0	18.97	18.97	-0.17	-0.47
Strategie In-Sample 1981–1985 & 1986–1990	32	47	74	15.95	2.89	6.56	9.93	1.61	0.79
Benchmark- strategie	100	50	0	13.05	0	20.49	20.49	0.64	0.24
Strategie Out- Of-Sample 1991	13	53	1	15.00	-11.62	2.19	8.15	1.84	1.17
Benchmark- strategie	100	48	0	26.62	0	16.82	16.82	1.58	1.26
Strategie In-Sample 1982–1986 & 1987–1991	45	53	90	21.43	5.21	9.25	11.78	1.82	1.21
Benchmark- strategie	100	50	0	16.22	0	20.55	20.55	0.79	0.44
Strategie Out- Of-Sample 1992	11	49	8	1.13	-6.24	1.25	3.97	0.28	-0.58
Benchmark- strategie	100	50	0	7.37	0	11.40	11.40	0.65	0.35
Strategie In-Sample 1983–1987 & 1988–1992	71	54	83	22.78	7.79	14.02	17.40	1.31	0.94
Benchmark- strategie	100	51	0	14.99	0	19.74	19.74	0.76	0.43
Strategie Out- Of-Sample 1993	69	55	4	10.73	1.13	6.99	8.68	1.24	0.90
Benchmark- strategie	100	51	0	9.60	0	10.13	10.13	0.95	0.66
Strategie In-Sample 1984–1988 & 1989–1993	78	54	94	22.77	8.85	15.10	15.66	1.45	1.08
Benchmark- strategie	100	51	0	13.92	0	19.36	19.36	0.72	0.42
Strategie Out- Of-Sample 1994	63	52	13	0.26	-1.00	7.33	9.25	0.03	-0.43
Benchmark- strategie	100	50	0	1.26	0	11.64	11.64	0.11	-0.26
Strategie In-Sample 1985–1989 & 1990–1994	87	53	65	19.99	6.55	16.64	15.76	1.27	0.93
Benchmark- strategie	100	52	0	13.44	0	19.13	19.13	0.70	0.43
Strategie Out- Of-Sample 1995	93	58	16	21.00	0.09	8.62	9.15	3.50	2.89
Benchmark- strategie	100	58	0	31.91	0	9.27	9.27	3.44	2.84

	Aktienanteil in %	Trefferquote in %	Anzahl Switches	Gesamt- rendite p.a. in %	Performance p.a. in %	Anteilige Volatilität p.a. in %	Tatsächliche Volatilität p.a. in %	Rendite/ Risiko Ratio p.a.	Sharpe Ratio p.a.
Strategie In-Sample 1986–1990 & 1991–1995	89	53	67	22.24	8.37	16.90	15.53	1.43	1.11
Benchmark- strategie	100	52	0	13.87	0	18.99	18.99	0.73	0.46
Strategie Out- Of-Sample 1996	99	52	2	20.67	0.01	13.83	13.89	1.49	1.12
Benchmark- strategie	100	51	0	20.66	0	13.89	13.89	1.49	1.12
Strategie In-Sample 1987–1991 & 1992–1996	84	53	105	21.28	7.06	15.71	15.19	1.40	1.07
Benchmark- strategie	100	52	0	14.22	0	18.70	18.70	0.76	0.49
Strategie Out- Of-Sample 1997	33	48	5	7.16	-21.62	7.07	14.97	0.48	0.13
Benchmark- strategie	100	53	0	28.78	0	21.41	21.41	1.34	1.10
Strategie In-Sample 1988–1992 & 1993–1997	85	52	53	18.89	2.29	13.13	13.71	1.38	1.02
Benchmark- strategie	100	52	0	16.59	0	15.45	15.45	1.07	0.76
Strategie Out- Of-Sample 1998	84	54	14	22.13	-2.71	20.08	23.15	0.97	1.05
Benchmark- strategie	100	54	0	25.13	0	23.90	23.90	1.05	0.85
Strategie In-Sample 1989–1993 & 1994–1998	49	49	23	11.44	-6.14	7.84	11.82	0.97	0.56
Benchmark- strategie	100	52	0	17.57	0	15.97	15.97	1.10	0.80
Strategie Out- Of-Sample 1999	39	51	5	20.46	1.36	8.27	13.48	1.52	1.17
Benchmark- strategie	100	49	0	19.10	0	21.20	21.20	0.90	0.68
Strategie In-Sample 1990–1994 & 1995–1999	74	51	49	15.18	-1.55	12.29	14.31	1.06	0.73
Benchmark- strategie	100	51	0	16.73	0	16.61	16.61	1.01	0.72
Strategie Out- Of-Sample 2000	88	50	2	-4.52	5.02	23.07	25.86	-0.17	-0.40
Benchmark- strategie	100	46	0	-9.54	0	26.22	26.22	-0.36	-0.60

Die Anzahl der “Switches” oder Investitionswechsel hingegen ist im allgemeinen von der Zeitdauer einer Investitionsperiode abhängig. Bei diesem Parameter wurde jedoch auf eine Standardisierung bezüglich einer Referenzinvestitionsdauer verzichtet. Zum einen ist dieser Schritt nötigenfalls problemlos durchführbar, zum anderen bleibt so die absolute und tatsächliche Anzahl der Investitionswechsel der jeweils gemessenen Strategien im Zusammenhang mit den zugehörigen Datenzeiträumen erhalten. Da passive Strategien ipso facto in derselben Anlageklasse verbleiben, ist die Anzahl der Switches

der Benchmarkstrategien stets Null. Investitionswechsel sind insbesondere im Zusammenhang mit Transaktionskosten zu sehen. Auch wenn diese im Rahmen des verwendeten Modells unberücksichtigt bleiben, so ist eine geringe Wechselrate bei der Gesamtbeurteilung einer Strategie ein positiver Indikator. Vor diesem Hintergrund ist zu bedenken, dass das Auffinden grösserer Markttrends unter Inkaufnahme geringerer Trefferquoten bei einer deutlich verringerten Anzahl von Investitionswechsel durchaus eine ernsthafte Alternative hinsichtlich der anzustrebenden Strategieanweisungen bei der Identifikation der Timingstrategien gegenüber optimalen Markttings im weiter oben angesprochenen Sinne darstellt.

Die Gesamrendite weist für alle Strategien die auf ein Jahr standardisierten insgesamt erzielten Renditen in Prozent aus. Die Performance weist die ebenfalls auf ein Jahr bezogene Differenz zwischen Timingstrategie und zugehöriger Benchmarkstrategie aus. Damit ist dieses Mass für die Buy-and-Hold Strategien stets Null, während bei den Timingstrategien hier auch negative Prozentsätze auftreten können. Beide Bewertungskriterien abstrahieren jedoch von allfälligen Risiküberlegungen. Zwar ist es naheliegend, dass eine hohe Performance mit einer eher guten Strategie einhergeht, doch ist insbesondere im Rahmen der Überlegungen zu den Aktienanteilen das sich daraus ableitende individuelle Risikoprofil einer Strategieanwendung jeweils zu beachten.

Die anteilige Volatilität ergibt sich aus der Gesamtvolatilität des Datenzeitraumes bezogen auf den Aktienanteil. Neben einer Renditemaximierung soll damit über den Vergleich zu der tatsächlichen Volatilität der jeweiligen Strategie indiziert werden, inwieweit über die Investitionsregel gleichzeitig eine Minimierung des Risikos einhergeht. Entspricht daher die anteilige Volatilität der tatsächlichen, so findet im Rahmen der betreffenden Investitionsanweisung eine dem Aktienanteil entsprechende proportionale Risikoreduktion statt. Liegt die tatsächliche Volatilität unterhalb der anteiligen, so weist dies darauf hin, dass tendenziell in Perioden mit tiefer Volatilität das risikobehaftete Asset gehalten wird. Alle Angaben zur Volatilität sind annualisiert dargestellt.

Das Sharpe-Ratio stellt durch die Einbeziehung des Risikos das wesentliche Bewertungskriterium zur Messung des Timingerfolges dar. Allerdings handelt es sich bei allen Performancekomponenten um ex post Grössen. Damit sind Konstellationen denkbar, die zu negativen Sharpe-Ratios trotz positiver erzielter Renditen führen. Daher werden auch die Rendite-Risiko-Verhältnisse ohne Einbezug der jeweils risikofreien Renditen dargestellt. Allfällige negative Rendite-Risiko-Ratios bzw. Sharpe-Ratios werden dargestellt und trotz ihrer beschränkten Aussagekraft in den nachfolgenden Auswertungen, speziell aber bei der Berechnung der Werte in Tabelle 4 berücksichtigt, um Verzerrungen der Ergebnisaggregationen zu vermeiden, da kleinere negative Werte grösseren negativen Sharperatios eindeutig überlegen sind.

Tabelle 4: Aggregierte Werte aus Tabellen 1 bis 3

	Gesamperiode								Subperiode 80er							
	Buy-and-Hold				Markttiming				Buy-and-Hold				Markttiming			
	5J/5J	5J/1J	10J/1J	Schnitt	5J/5J	5J/1J	10J/1J	Schnitt	5J/5J	5J/1J	10J/1J	Schnitt	5J/5J	5J/1J	10J/1J	Schnitt
Durchschnittliche Aktienanteile in %	100.00	100.00	n.v.	100.100	64.75	70.06	n.v.	67.41	100.00	100.00	n.v.	100.00	53.00	56.00	n.v.	54.50
Durchschnittliche Trefferquoten in %	51.92	51.75	n.v.	51.84	52.00	52.00	n.v.	52.00	52.20	53.40	n.v.	52.80	52.40	52.80	n.v.	52.60
Durchschnittliche Wechselraten (absolut p.a.)	0.00	0.00	n.v.	0.00	5.42	9.25	n.v.	7.34	0.00	0.00	n.v.	0.00	6.92	9.60	n.v.	8.26
Durchschnittliche Überschussrenditen in %	0.00	0.00	n.v.	0.00	-0.73	-0.63	n.v.	-0.68	0.00	0.00	n.v.	0.00	3.18	3.76	n.v.	3.47
Durchschnittliche Sharperatios	0.67	0.73	n.v.	0.70	0.80	0.89	n.v.	0.85	0.47	0.84	n.v.	0.66	0.97	1.37	n.v.	1.17
Durchschnittliche tatsächliche Volatilitäten in %	17.64	18.09	n.v.	17.87	12.87	13.51	n.v.	13.19	20.53	20.92	n.v.	20.73	12.44	11.91	n.v.	12.18

	Subperiode 90er								Anteil Bessere an Gesamtperiode							
	Buy-and-Hold				Markttiming				Buy-and-Hold				Markttiming			
	5J/5J	5J/1J	10J/1J	Schnitt	5J/5J	5J/1J	10J/1J	Schnitt	5J/5J	5J/1J	10J/1J	Schnitt	5J/5J	5J/1J	10J/1J	Schnitt
Durchschnittliche Aktienanteile in %	100.00	100.00	100.00	100.100	73.14	76.45	59.36	69.65	100.00	100.00	100.00	100.00	0.00	0.00	0.00	0.00
Durchschnittliche Trefferquoten in %	51.71	51.00	51.09	51.27	51.71	51.64	52.45	51.93	25.00	18.75	18.18	20.64	75.00	81.25	81.82	79.36
Durchschnittliche Wechselraten (absolut p.a.)	0.00	0.00	0.00	0.00	4.34	9.09	8.82	7.42	0.00	0.00	0.00	0.00	100.00	100.00	100.00	100.00
Durchschnittliche Überschussrenditen in %	0.00	0.00	0.00	0.00	-3.52	-2.63	-1.65	-2.60	50.00	62.50	45.45	52.65	50.00	37.50	54.55	47.35
Durchschnittliche Sharperatios	0.81	0.69	0.68	0.73	0.68	0.67	0.71	0.69	33.33	43.75	36.36	37.81	66.67	56.25	63.64	62.19
Durchschnittliche tatsächliche Volatilitäten in %	15.57	16.80	16.80	16.39	13.17	14.24	12.90	13.44	0.00	0.00	0.00	0.00	100.00	100.00	100.00	100.00

In Tabelle 4 werden die relevantesten Bewertungsparameter der Tabellen 1 bis 3 aggregiert. Es werden jeweils Durchschnittswerte für die verschiedenen Untersuchungskonstellationen ausgewiesen. Dabei werden stets die Resultate der aktiven bzw. passiven Strategien getrennt gezeigt. Alle Auswertungen können unmittelbar miteinander und untereinander verglichen werden. Zusätzlich werden die Gesamtdurchschnitte jeder Strategieart über alle Anwendungskombinationen hinweg dargestellt, was einen Gesamtvergleich von Benchmark und Markttimingstrategie ermöglicht. Da die Untersuchungsergebnisse für die 80er bzw. 90er Jahre sehr unterschiedlich sind, werden neben der Aggregation über die Gesamtperiode auch nach Subsamples gegliederte Durchschnittswerte gebildet. Zur Subperiode 80er Jahre zählen dabei alle Anwendungen, die 1989 stattfanden bzw. spätestens in diesem Jahr begannen. Anwendungen, die sich auf Daten des Jahres 2000 bezogen, wurden aus Gründen der Vereinfachung der Subperiode 90er Jahre zugeordnet. Mit dem "Anteil der besseren Resultate an der Gesamtperiode" wird der prozentuale Anteil der jeweils superioren Werte der zugrundeliegenden Einzelauswertungen des jeweiligen Gesamtuntersuchungszeitraumes gezeigt. Da sich das Interesse an dem out-of-Sample Verhalten der getesteten Strategien orientiert, werden nur diese Ergebnisse in Tabelle 4 berücksichtigt. Neben den verschiedenen Wertausprägungen der Timingstrategien existieren zunächst Divergenzen der Wertausprägungen der Buy-and-Hold Strategien sowohl bei den Trefferquoten als auch bei den Angaben zu den Sharpe-Ratios und Volatilitäten, wie besonders in Tabelle 4 sichtbar wird. Da jedoch bei der Untersuchungskombination 5 Jahre Optimierung/5 Jahre Anwendung stets mit annualisierten Werten mit entsprechendem Abweichungspotential zu den direkt auf jährlicher Basis gefundenen Resultaten operiert wird, besteht allenfalls ein detaillierterer Erklärungsbedarf nur bezüglich der dargestellten Werte der Benchmarkstrategien der beiden Untersuchungskombinationen 5 Jahre Optimierung/1 Jahr Anwendung resp. 10 Jahre Optimierung/1 Jahr Anwendung in der Subperiode 90er Jahre, weil dort zunächst eine identische Datenbasis und Ergebnispräsentationsbasis vorliegt. Genau an dieser Stelle stimmen jedoch für die gezeigten Werte für die Volatilitäten (jeweils 16,8%) exakt überein. Ein marginales Delta in Höhe von 0,09 bzw. 0,01 ergibt sich an dieser Stelle jedoch für die angegebene durchschnittliche Trefferquote in % sowie die durchschnittlichen Sharperatios. Da die ausgewiesenen Größen Durchschnittswerte eines aus je 11 Einzelwerten bestehenden Subsamples sind, handelt es sich bei der fraglichen Differenz um einen Rundungsfehler im Rahmen der den errechneten Durchschnittswerten zugrundeliegenden Datengrundlagen der Tabellen 2 und 3 und ist daher unbeachtlich.

Alle Interpretationen und Vergleiche beziehen sich v.a. auf die out-of-Sample erreichten Ergebnisse, da in-sample stets eine Outperformance durch Markttiming erreicht werden konnte. Zu beachten ist dabei jedoch die Besonderheit der in Tabelle 3 gemachten in-sample Untersuchung. Da hier, wie bereits bemerkt, die via Optimierung identifizierten Strategien mit zwangsläufig die Performance beeinflussenden zwei mal fünfjährigen anstatt einmal zehnjährigen Datenperioden getestet wurden, besteht auch bei insgesamt identischen Daten hier kein Automatismus zwischen Überschussrendite und

in-sample Test. Wurde z. B. eine Strategie über eine zugrundeliegende Datenhistorie von 1980–1989 identifiziert, so wurde der in-sample Test mit zwei Datensätzen, die sich von 1980–1984 sowie 1985–1989 erstreckten und so die mit dem Optimierungslauf kongruente Historie darstellen, durchgeführt. Aufgrund der dem Methodenset immanenten und für die Timingstrategien essentiellen Schwellenwertklassen der Erklärungsvariablen entstehen damit jedoch für jeden Subdatensatz eigene Ausprägungen der jeweils identifizierten Klassen. Dementsprechend ergibt sich hinsichtlich der in-sample Resultate eine Divergenz zwischen den Ergebnissen des Optimierungs- und dem in-sample Testlauf, der unter Verwendung identischer Datensätze, also ohne Unterbrechung der Gesamthistorie, nicht auftreten kann. Auf die out-of-sample Tests hat diese Besonderheit der in Tabelle 3 dargestellten Untersuchung keine Implikationen, so dass die Ergebnisse mit denen der anderen Tabellen vergleichbar sind. Ausserdem ist beim Vergleich der Tabellen zu beachten, dass für die Anwendungskonstellation in Tabelle 3 nur Ergebnisse der 90er Jahre vorliegen. Ein Vergleich über alle Resultate der Tabelle 4 zeigt jedoch generell, dass die Investitionsregeln in den 80er Jahren deutlich erfolgreicher zu sein schienen. Trotzdem kann besonders mit der in Tabelle 3 gezeigten Anwendung gerade während dieses kritischen Zeitraumes risikoadjustiert eine Outperformance mit einem durchschnittlichen Sharperatio von 0,71 gegenüber 0,68 des Benchmarks nachgewiesen werden (vgl. Tabelle 4).

Die annualisierten Gesamtsummen der jeweils ausgewiesenen Überschussrenditen sind bei allen drei dargestellten Anwendungskonstellationen mit durchschnittlich $-8,77\%$, $-10,13\%$ und $-18,20\%$ in den Tabellen 1, 2 und 3 negativ. Dabei ist jedoch zu berücksichtigen, dass hierbei von jeder Risikobetrachtung abgesehen wird. Weiter ist die Bandbreite der unterschiedlichen Überschussrenditen innerhalb der Varianten jeweils sehr gross. Es fällt auf, dass v.a. mit auf in den 80er Jahren liegenden Anwendungszeiträumen gute Resultate erzielt werden können, diese sich jedoch in den 90er Jahren nicht fortsetzen. So sind z. B. in der Subperiode "80er" der Tabelle 4 die gesamt durchschnittlichen Überschussrenditen mit $3,47\%$ p.a. positiv, während sie in den 90ern mit $-2,60\%$ negativ werden. Der Eindruck festigt sich bei der Betrachtung der Sharpe-Ratios der Timingstrategien, welche ebenfalls in den 80ern mit gesamt durchschnittlich 1,17 gegenüber 0,69 in den 90ern signifikant höher liegen. Eine mögliche Ursache könnte in der sich über die Zeit ändernden Relevanz und Migration der das Bezugssystem erklärenden Variablen sowie auch der Tatsache liegen, dass es in einem generell und kontinuierlich steigenden Markt schwieriger ist, mit einer Strategie, welche nicht immer 100% in Equity ist, den Markt zu schlagen.

In diesem Zusammenhang stellt sich auch die Frage der Wahl des Verhältnisses zwischen Optimierungs- und anschliessender Anwendungsdauer der identifizierten Strategien. Zu lange Optimierungsperioden könnten dazu führen, dass in die Lösungssuche hinsichtlich zukünftiger Sachverhalte irrelevante Informationen einfließen. Ist der Identifikationszeitraum jedoch zu kurz, steht hingegen zu befürchten, dass in einer dann zu knappen Datenmenge wesentliche Informationen fehlen. Über die durchschnittlichen Sharpe-Ratios der durchgeführten Anwendungsvariationen kann zu die-

sem Sachverhalt eine Aussage gemacht werden. Obwohl nur 56,25 % gegenüber 66,67 % bzw. 63,64 % aller Ratios höher als diejenigen der jeweiligen Benchmarkstrategien waren, konnte mit der Kombination aus 5 Jahren Optimierungszeitraum und einjähriger Anwendungsdauer im Anschlusszeitraum ein Ergebnis erzielt werden, dass sowohl zu den Werten aus den beiden anderen in-sample/out-of-sample Varianten als auch im Vergleich der Differenzen zu den jeweiligen durchschnittlichen Sharpe-Ratios der Benchmarkstrategien mit 0,89 über den Gesamtzeitraum den eindeutig höchsten Wert aufwies (vgl. Tabelle 4). Dabei ist jedoch zu betonen, dass die Ergebnisse in Tabelle 3 nur in dem für die Strategien offensichtlich ohnehin schwierigen Zeitraum der 90er Jahre getestet werden konnten. Werden die Resultate dieser Übersicht mit den analogen Grössen der anderen Tabellen verglichen, so konnten mit einem Optimierungs-/Anwendungszeitraumverhältnis von 10 zu 1 mit 0,71 sowohl gegenüber den alternativen Anwendungsvarianten als auch gegenüber dem zugehörigen Benchmark die besten Ergebnisse erzielt werden. Die dort gezeigten Ergebnisse weisen somit als einzige eine risikoadjustierte Outperformance gegenüber dem Benchmark auch in den 90er Jahren aus, ein Indiz für die Zweckmässigkeit, lange Datenhistorien während der Optimierung mit relativ kurzen Anwendungshorizonten zu verknüpfen.

Im Rahmen dieses Vergleiches waren über die Gesamtperiode alle durchschnittlichen Sharpe-Ratios der Timingstrategien in den out-of-sample Anwendungen mit 0,85 gegenüber 0,70 eindeutig höher als jene der Benchmarkstrategien (vgl. Tabelle 4). Das durchschnittliche Sharpe-Ratio der in Tabelle 1 durchgeführten Anwendung betrug 0,80 gegenüber einem Durchschnitt von 0,67 der zugehörigen Benchmarkstrategien. Für die in Tabelle 2 und 3 durchgeführten Anwendungen ergaben sich jeweils Werte von 0,89 gegenüber 0,73 resp. 0,71 gegenüber 0,68. Mit jeder der getesteten Anwendungen konnte somit unter Berücksichtigung der zugehörigen Risiken eine Outperformance nachgewiesen werden, obwohl der Prozentsatz der jeweils höheren Sharpe-Ratios der aktiven Strategien im Vergleich zu jenen der zugehörigen Benchmarkstrategien mit 66,67 %, 56,25 % bzw. 63,64 % jedenfalls für die in Tabelle 2 durchgeführte Untersuchung nicht a priori die Superiorität der Timingstrategien indizierte.

Bei der Betrachtung der Volatilitäten fällt auf, dass nur in ganz wenigen Ausnahmen (Tabelle 1 Strategie out-of-sample 1996–2000 sowie Tabelle 2 Strategie out-of-sample 1987) die tatsächliche Volatilität unterhalb der Anteiligen liegt. Da das Maximierungsziel in der Rendite lag, gelang in diesen Fällen jedoch ein zusätzlicher Erfolg, indem neben einer Überschussrendite parallel das Risiko überproportional verringert wurde. Die Investitionsanweisungen führten in diesen Fällen also in besonderem Masse dazu, überdurchschnittlich positive Renditen zu identifizieren und gleichzeitig Renditen mit hoher zugehöriger Volatilität bzw. negative Renditen durch Investitionen in risikofreie Assets zu umgehen. Dass insbesondere dieser Erfolg der Strategie aus Tabelle 2 mit nur einem Investitionsklassenwechsel gelang, weist darauf hin, dass die Strategie eher langfristige und nachhaltige Trends im Verlauf des risikobehafteten Assets antizipierte. Hinzu kommt das besondere Marktverhalten im Jahre 1987 als weiterer Hinweis auf den vorteilhaften Einsatz von aktiven Strategien insbesondere bei ausgeprägten und nachhalti-

gen Verhaltensweisen der Kapitalmärkte. Insgesamt erscheint die Anzahl der gemessenen Investitionswechsel im Vergleich zu den zugehörigen Investitionszeiträumen eher moderat, wobei in-sample häufigere Wechsel stattfanden als out-of-sample. Diese Tatsache ist unter Berücksichtigung der Methodik intuitiv nachvollziehbar und korrespondiert mit den besseren Renditeziffern der in-sample Tests, da durch die in-sample Iterationen differenziertere Verhaltensmuster in den Daten gesucht und umgesetzt werden konnten. Der Gesamtdurchschnitt der Investitionswechsel über alle out-of-sample angewendeten Strategien lag bei 7,38 Wechseln pro Strategie und Jahr gegenüber einem Wert von rd. 10,1 bei einer in-sample Anwendung. Da bei erfolgreichen Strategien häufiges Wechseln in Verbindung mit hohen Trefferquoten das Potential eines Markttimings erschliesst, es bei hohen Fehlerquoten durch den zusätzlichen Effekt der Transaktionskosten aber weitgehend vernichtet, sind geringe Wechselquoten ein Indikator, der die Hypothese der Identifikation eher längerfristiger Trends unterstützt und insbesondere dann als positives Signal zu interpretieren ist, wenn die gefundenen Lösungen das Bezugssystem eher approximativ antizipieren können. Genau dies ist hierbei allein schon aufgrund der Restriktionen bei der Anzahl möglicher Erklärungsvariablen der Fall. Dabei wird anhand des dem Suchraum zugrundeliegenden Schwellenwertkonzeptes der Variablenwerte eine methodische Implementation von Nichtlinearitäten dargestellt. Diese simplifiziert jedoch aufgrund der je gleichverteilten und grosszügigen Bandbreiten die Komplexität des Bezugssystems. Hierin liegt ein weiterer wesentlicher Anhaltspunkt dafür, warum die identifizierten Lösungen eher längerfristige und substantielle Trends in bewegteren Marktumfeldern aufspüren können als kurzfristige Switches zu signalisieren. Im Rahmen eines erweiterten Detaillierungsgrades dieser Schwellenwertlogik können ggf. im Zusammenhang mit einer grösseren Erklärbarkeit der Gesamtvarianz des Marktes durch den Einbezug weiterer ökonomischer Variablen, differenziertere Ergebnisse erreicht werden.

Trotz der limitierten Aussagekraft der Trefferquoten fällt auf, dass in der überwiegenden Zahl aller Fälle Werte in einem Intervall zwischen ca. 50 % bis 58 % erreicht werden, Werte unterhalb von 50 % nur in wenigen Situationen auftreten, durchaus aber auch in-sample erreicht werden und der Mittelwert der Ausprägungen bei rund 52 % liegt. Zu beachten ist dabei jedoch, dass die Trefferquoten der aktiven Strategien zu 79,36 % über denen der Passiven liegen und die durchschnittlichen Trefferquoten der aktiven Strategien in allen Fällen über jenen der passiven Strategien liegen. Die Prognosekraft der identifizierten Timingstrategien übersteigt somit jene der passiven Investitionsregeln. Die positive Differenz der durchschnittlichen Trefferquoten von Timing- und Benchmarkstrategien kann als Indiz einer den aktiven Strategien immanenten Prognosekraft aufgefasst werden, die im Rahmen einer Informationsgeneration über die Vorgehensweise der Strategieermittlung einen Effizienzvorsprung und damit Timingpotential ermöglicht.

Insgesamt zeigt Tabelle 4 durch die Aggregation der Ergebnisse über die beiden Subsamples eindeutig, dass es im Vergleich zu der Entwicklung der unterstellten risikobehafteten Anlageklasse schwierig schien, besonders in Zeiten stark steigender Kurse

die Buy-and-Hold Strategien outzuperformen, was noch am ehesten den in Tabelle 3 vorgestellten Anwendungen gelang. Diese Aussage korrespondiert mit der Erkenntnis, dass Markttiming sich v.a. bei aussergewöhnlichen kursrelevanten Ereignissen bzw. Distressszenarien als erfolgreich dargestellt hat. So konnten sowohl in den Zeiträumen von 1987 sowie 1990 stets und in allen Anwendungsvarianten überdurchschnittlich gute Resultate erzielt werden. Die Intuition ist nachvollziehbar, da in besonders erfolgreichen und kontinuierlichen Phasen schon zum Erzielen der mit passiven Strategien erreichbaren Renditen hohe Aktienanteile erforderlich sind. Nur besonders erfolgreiche Investitionsregeln mit ausserordentlichen Erklärungsgehalten hinsichtlich des Bezugssystems könnten noch die wenigen optimalen Investitionswechsel eines in einem steilen Aufwärtstrend befindlichen Risikoassets auffinden, welche allenfalls zu einer Outperformance führen würden. Strategien, welche, selbst wenn zuverlässig, eher langfristige Trends zu identifizieren vermögen, werden jedoch einzelne zwischentägliche Investitionswechsel zugunsten der allgemeinen Entwicklung und vorherrschenden Risikolage übergehen.

Ein Blick auf den Chart zeigt in diesem Zusammenhang eine relativ kontinuierliche Kursentwicklung über weite Strecken in den 90er Jahren im Gegensatz zu den Kursverläufen der 80er Jahre. Die Summe aller angesprochenen Hinweise führt zu dem Schluss, dass Markttiming bzw. die erfolgreiche Identifikation von Investitionswechseln insbesondere in ereignisreichere und damit volatilere Zeiträume bei eher niedriger Gesamtrendite fiel. Dies war über weite Strecken in den 80er Jahren stärker der Fall als in der darauffolgenden Dekade. Die in den Tabellen dargestellten Zahlen unterstützen diese Aussage. Der Einsatz der im Rahmen der vorgestellten Methodik entwickelten Handelsstrategien konnte dann zu einer erheblichen Verbesserung der erzielten Performance beitragen. In Übereinstimmung mit anderen Studien (vgl. OLSON und MOSSMANN, 2001; PESARAN und TIMMERMANN, 1995) fällt auf, dass Prognosemöglichkeiten zu unterschiedlichen Marktsituationen verschieden stark ausgeprägt scheinen. Insbesondere in Phasen deutlicher kursrelevanter Signale, wie nachhaltige Trendwechsel, Schocks etc., scheinen dort besondere Erfolge mit aktiven Strategien möglich. Diese Aussage kann auch im Hinblick der hier gefundenen Ergebnisse unterstützt werden. Weitere Übereinstimmung kann in der Vermutung festgestellt werden, dass sich der Einfluss bzw. die Relevanz von Prognosevariablen hinsichtlich des zu erklärenden Bezugssystems verändern kann (PESARAN und TIMMERMANN, 1995). Ausserdem wurde deutlich, dass Erfolge, insbesondere über langfristig angelegt Prognosemodelle bzw. Datenhistorien, gezeigt werden können. Auch hier findet sich eine Bestätigung in der begründbaren Intuition, dass die hier erkannten Strategien eher längerfristige und anhaltende Tendenzen identifizieren konnten. Insbesondere bei numerischen Vergleichen mit thematisch verwandten Studien sind jedoch stets die jeweils spezifischen Erfolgskriterien, Datenhorizonte und Anwendungszeiträume, Strategiekonstruktionen sowie zulässige Investitionsklassen und ähnliche Restriktionen zu beachten, die jeweils sehr unterschiedlich angelegt sein können und auf die Resultate erheblichen Einfluss nehmen. Dies macht direkte Vergleiche der absoluten Resultate nur bedingt möglich.

Die berechneten Resultate inspirierten aber noch zu einer weiteren Anwendungsmöglichkeit der über die Optimierungen erhaltenen Strategien. Wie bereits angedeutet, waren Verbesserungen in der Nähe des approximativen globalen Optimums nur marginaler Art. Zudem kann die Gefahr eines Overfittings nicht ausgeschlossen werden. Dies deutet darauf hin, dass neben der absoluten Bestlösung auch die anderen Lösungen im engen Näherungsbereich zu guten out-of-Sample Resultaten führen können. Gleichzeitig kann so die Problematik des Overfittings etwas entschärft werden. Es liegt daher auf der Hand, diese Potentiale im Rahmen einer parallelen Verwendung mehrerer Strategien gleichzeitig zu nutzen und damit zusätzlich Diversifikationseffekte zu realisieren. Analog zu den Erwägungen des klassischen Portfoliogedankens könnten durch eine Diversifikation über Strategien die Risiken bei der Anwendung einer möglicherweise nur suboptimalen Strategie reduziert werden. Mit den im Rahmen der in Tabelle 3 dargestellten Anwendungsvariation durchgeführten Optimierungen wurden Portfolios aus den jeweils 3 besten Lösungen je Identifikationszeitrahmen zusammengestellt und out-of-sample getestet. Es wurde dabei angenommen, dass in die jeweiligen Dreierportfolios zu gleichen Anteilen investiert wurde. Die Summe der sich daraus ergebenden durchschnittlichen Überschussrenditen lag auf Anheb um 1,65 % (oder 0,17 % p.a.) über jener, die sich aus der Anwendung stets nur einer Strategie ergab. Hinzu kommt der Effekt aus der zusätzlich resultierenden verminderten Risikosituation aufgrund des sich ergebenden Diversifikationseffektes. Die Idee der gleichzeitigen Verwendung mehrerer Strategien ist auch in der Hinsicht denkbar, dass neben der Portfoliobildung zuverlässig gute Strategien long, zuverlässig schlechte Strategien short gegangen werden. Investiert Strategie A z. B. in risikobehaftete Assets und ist Strategie A erfolversprechend, empfiehlt Strategie B eine risikolose alternative Anlage und führt diese Strategie stets zu Fehlentscheidungen, so kann aufgrund der Longposition aus der Empfehlung durch Strategie A und der diese finanzierende Shortposition aufgrund der Empfehlung aus Strategie B ein konzertierter Effekt anhand eines Leverage generiert werden. Das Risiko der aktiven Strategie kann in diesem Fall aber das Risiko der passiven Benchmarkstrategie übersteigen.

9. SCHLUSSFOLGERUNGEN

In dieser Arbeit wurden mit genetischen Algorithmen fundamental orientierte, aktive Handelsstrategien identifiziert, welche eine Timingstrategie implementieren mit dem Ziel, gegenüber einer passiven Benchmarkstrategie eine Outperformance zu erreichen. Die Methode wird auf den S&P 500 Composite Index angewandt, indem die Handelsstrategien Phasen bzw. Zeitpunkte indizieren, wann in diese Anlageklasse bzw. in die risikofreie Alternativanlage zu investieren ist. Die Strategieanweisungen beruhen auf 5 ökonomischen Erklärungsvariablen, die durch verschiedene Operatoren miteinander verknüpft sind. Dies führt zu konkreten Handelsanweisungen für jeden zugrundeliegenden Datensatz für jeweils eine der beiden möglichen Assetklassen. Insbesondere unter

einer risikoadjustierten Betrachtungsweise kann eine Outperformance gegenüber der Benchmarkstrategie nachgewiesen werden, wobei auf die Berücksichtigung von Transaktionskosten verzichtet wird. Dies ist in dieser Studie aber insofern unerheblich, weil v.a. längerfristige und nachhaltige Kursbewegungen identifiziert werden, was mit geringen Wechselraten zwischen den Anlageklassen einhergeht. Die erzielten Resultate veranschaulichen das Potential genetischer Algorithmen in der Identifizierung komplexer ökonomischer Zusammenhänge. Die hier dargestellten Untersuchungs- und Anwendungskonstellationen können in fast beliebiger Zahl variiert werden. Allenfalls könnte durch den Einbezug einer grösseren Anzahl ökonomischer Variablen ein höherer Anteil der Gesamtvarianz des Marktes erklärt und somit die Ergebnisse noch verbessert werden.

LITERATUR

- ALLEN, F. und R. KARJALAINEN (1999), "Using genetic Algorithms to find technical trading rules", *Journal of Financial Economics*, 51, S. 245–271.
- ALLEN, P.M. und H.K. PHANG (1994), "Managing Uncertainty in Complex Systems", in: L. Leydesdorff und P. van den Besselaar (Hrsg.), *Evolutionary Economics and Chaos Theory*, London, S. 125–135.
- BAUER, JR., R.J. (1994), *Genetic Algorithms And Investment Strategies*, New York.
- BAUER, JR., R.J. und G.E. LIEPINS (1992), *Genetic Algorithms and Computerized Trading Strategies*, in: D.E. O'Leary und P.R. Watkins (Hrsg.), *Expert Systems in Finance*, New York, S. 89–100.
- BÄCK, T. (1996), *Evolutionary Algorithms in Theory and Practice*, New York, Oxford.
- BREEN, W., L. GLOSTEN und R. JAGANNATHAN (1989), "Economic Significance of Predictable Variations in Stock Index Returns", *Journal of Finance*, 44, S. 1177–1189.
- BROCK, W., J. LAKONISHOK und B. LEBARON (1992), "Simple Technical Trading Rules and the Stochastic Properties of Stock Returns", *Journal of Finance*, 47, S. 1731–1764.
- CAMPBELL, J. und J. COCHRANCE (1999), "By force of habit: A consumption-based explanation of aggregate stock market behavior", *Journal of Political Economy*, 107, S. 205–251.
- CHAMBERS, L. (1995), "Preface", in: L. Chambers (Hrsg.), *Practical Handbook of Genetic Algorithms*, Volume I, New York.
- FAMA, E. (1970), "Efficient Capital Markets: A Review of Theory and Empirical Work", *Journal of Finance*, 25, S. 383–417.
- FAMA, E.F. und K.R. FRENCH (1989), "Business conditions and expected returns on stocks and bonds", *Journal of Financial Economics*, 25, S. 23–49.
- FEISTEL, R. (1997), "Evolution im Eigenschaftsraum", in: H.J. Krug und L. Pohlmann (Hrsg.), *Selbstorganisation, Jahrbuch für Komplexität in den Natur-, Sozial- und Geisteswissenschaften*, Band 8, Berlin, S. 97–111.

- FERSON, W.E. und C.R. HARVEY (1993), "The risk and predictability of international equity returns", *Review of Financial Studies*, 6, S. 527–566.
- GENETIC AND EVOLUTIONARY ALGORITHM TOOLBOX FOR USE WITH MATLAB (2000), www.geatbx.com/, 18.03.2001.
- GOLDBERG, D.E. (1989), *Genetic Algorithms in Search, Optimization and Machine Learning*, Reading (Massachusetts).
- GROSSMANN, S. und J. STIGLITZ (1980), "On the Impossibility of Informationally Efficient Markets", *American Economic Review*, 70, S. 393–408.
- HOLLAND, J.H. (1994), *Adaptation in Natural and Artificial Systems*, Cambridge (Massachusetts), London, 3rd Edition.
- KINNEBROCK, W. (1994), *Optimierung mit genetischen und selektiven Algorithmen*, München.
- KUAN, C.M. und T. LIU (1995), "Forecasting exchange rates using feedforward and recurrent neural networks", *Journal of Applied Econometrics*, 10, S. 347–364.
- KWAN, J.W.C., K. LAM, M.K.P. So und P.L.M. YU (2000), "Forecasting and Trading Strategies Based on a Price Trend Model", *Journal of Forecasting*, 19, S. 485–498.
- LO, A. und C. MACKINLAY (1988), "Stock Market Prices Do Not Follow Random Walk: Evidence from a Simple Specification Test", *Review of Financial Studies*, 1, S. 41–66.
- MAYR, E. (1967), *Artbegriff und Evolution*, Berlin.
- NISSEN, V. (1994), *Evolutionäre Algorithmen*, Wiesbaden.
- NISSEN, V. (1995), "An Overview of Evolutionary Algorithms in Management Applications", in: J. Biethahn und V. Nissen (Hrsg.), *Evolutionary Algorithms in Management Applications*, New York, S. 44–89.
- NISSEN, V. (1998), "Einige Grundlagen Evolutionärer Algorithmen", in: J. Biethahn, A. Hönerloh, J. Kuhl, M. C. Leisewith, V. Nissen und M. Tietze (Hrsg.), *Betriebswirtschaftliche Anwendungen des Soft Computing*, Braunschweig, S. 55–78.
- OLSON, D. und C. MOSSMAN (2001), "Cross-correlations and Predictability of Stock Returns", *Journal of Forecasting*, 20, S. 145–160.
- PESARAN, M. und A. TIMMERMANN (1995), "Predictability of stock returns: Robustness and economic significance", *Journal of Finance*, 50, S. 1201–1228.
- POHLHEIM, H. (2000), *Evolutionäre Algorithmen*, Berlin.
- REHKUGLER, H. und T. PODDIG (1991), "Künstliche Neuronale Netze in der Finanzanalyse: Eine neue Ära der Kursprognosen?", *Wirtschaftsinformatik*, 33, S. 365–374.
- REHKUGLER, H. und T. PODDIG (1990), "Statistische Methoden versus künstliche Neuronale Netzwerke zur Aktienkursprognose", *Betriebswirtschaftliche Beiträge*, Nr. 73, Universität Bamberg.
- RIDLEY, M. (1990), *Evolution*, Berlin.
- SCHEINKMAN, J.A. und B. LEBARON (1989), "Nonlinear Dynamics and Stock Returns", *Journal of Business*, 62(3), S. 1311–1337.
- SCHÖNEBURG, E., F. HEINZMANN und S. FEDDERSEN (1994), *Genetische Algorithmen und Evolutionsstrategien*, New York.

- TRIPPI, R.R. und D. DESIENO (1992), "Trading Equity Index Futures with a Neural Network", *Journal of Portfolio Management*, 19, S. 27–33.
- WAGNER, G.P. (1994), "Der Dialog zwischen Evolutionsforschung und Computerwissenschaft", in: W. Wieser (Hrsg.), *Die Evolution der Evolutionstheorie*, Berlin, S. 223–233.
- WUKETITS, F.M. (1985), "Die systemtheoretische Innovation der Evolutionslehre", in: J.A. Ott, G.P. Wagner und F.M. Wuketits (Hrsg.), *Evolution, Ordnung und Erkenntnis*, Berlin, S. 69–109.

SUMMARY

In this study of tactical asset allocation, we use a genetic algorithm to implement a market timing strategy. The algorithm makes a daily decision whether to invest in the market index or in a riskless asset. The market index is represented by the S&P500 Composite Index, the riskless asset by a 3-month T-Bill. The decision of the genetic algorithm is based on fundamental macroeconomic variables. The association of fundamental variables with a set of operators creates a space of possible strategies from which the genetic algorithm attempts to select the optimal solution. To test its performance, we apply the genetic algorithm to different time periods of in-sample and out-of-sample data using rolling return estimates. In total, 39 different timing strategies are tested over the time period of 1980–2000. On a risk-adjusted basis, we observe a moderate outperformance for the timing strategy suggested by the algorithm compared to a passive index strategy. The forecasting power of the algorithm is higher during times of high volatility and pronounced changes in the return series. Moreover, the algorithm is more successful in forecasting long-term return patterns than short-term fluctuations.

ZUSAMMENFASSUNG

In der vorliegenden Studie wird ein genetischer Algorithmus benutzt, um eine Markt-timing-Strategie zu implementieren. Der Algorithmus entscheidet jeweils täglich, ob in den Marktindex oder in eine risikolose Anlage investiert wird. Der Marktindex wird durch tägliche Renditen des S&P 500 Composite Index, die risikolose Anlage durch tägliche Renditen auf 3-monats T-Bills repräsentiert. Die Strategieanweisungen werden durch verschiedene zeitinvariante fundamentale ökonomische Variablen motiviert. Durch ihre Verknüpfung mit unterschiedlichen Operatoren entsteht ein Raum möglicher Strategien, dessen Optimum der Algorithmus approximiert, bewertet und auf diese Art Bestlösungen identifiziert. Die gefundenen Strategien werden rollierend auf unterschiedliche Kombinationen von in-sample- und out-of-sample Datenperioden angewendet. Insgesamt werden damit über einen Gesamtzeitraum von 1980–2000 39 verschiedene Timingstrategien identifiziert und getestet. Insbesondere in Phasen hoher

Volatilität und ausgeprägten Änderungen der Kursentwicklung können zufriedenstellende Resultate gegenüber einer passiven Benchmarkstrategie erzielt werden. Eine Prognosekraft kann v.a. hinsichtlich längerfristiger Trendverläufe festgestellt werden, so dass bei einer risikogerechten Betrachtungsweise der Ergebnisse eine leichte Outperformance der in dieser Untersuchung entwickelten Handelsstrategien festzustellen ist.

RÉSUMÉ

Dans la présente étude, nous utilisons un algorithme génétique pour implanter une stratégie de “timing” du marché. L’algorithme choisit quotidiennement entre un investissement dans un indice du marché ou un placement sans risque. L’indice du marché est représenté par le S&P Composite Index, le placement sans risque par un T-Bill sur 3 mois. Les décisions de l’algorithme génétique sont basées sur des variables macro-économiques fondamentales. L’association des variables fondamentales à une série d’opérateurs crée l’espace des stratégies possibles. L’algorithme en extrait l’optimum, l’évalue et identifie ainsi les meilleures solutions. Nous testons la performance de l’algorithme en l’appliquant à des données dites “in-sample” et “out-of-sample” sur différentes périodes de temps. Au total, 39 stratégies de timing différentes sont testées pendant la période de 1980–2000. Les résultats obtenus avec l’algorithme surpassent une stratégie passive de l’indice surtout en période de volatilité accrue et de variations marquées des cours boursiers. L’algorithme possède une capacité de prévision pour les trends à long terme; dans une optique tenant compte des risques, on constate donc une performance légèrement meilleure des stratégies développées dans cette étude.