

グロースファクターの合成方法と株式リターン に関する研究

The Study on the Relationship between the Method of Combining Growth Factors and the Stock Returns

青山学院大学大学院 国際マネジメント研究科 客員教授
大学共同利用機関法人統計数理研究所 リスク解析戦略研究センター 客員教授
ニッセイアセットマネジメント株式会社 投資工学開発センター長
吉野 貴晶
Takaaki Yoshino

(論文要旨)

本稿は、複数のグロース指標を取り上げて、それらの合成を行い、どのような合成方法が将来のリターンと関係があるのかを検証する。Asness, Frazzini and Pedersen(2019)で提示された5つのグロース指標を、我が国に適用して、(1) 等ウェイト、(2) 主成分ウェイト、(3) 回帰係数法、(4) 合成IC最大化法、(5) ニューラルネット(NN)法の5つの方法で合成するグロースファクターとリターンとの関係を観察する。その結果、グロースの合成ファクターが銘柄選択にある程度、有効に機能する可能性が示された。しかし、その銘柄選択効果は統計的に有意とはならなかった。今回、検証した合成方法のうち最も効果的だったのは(3)回帰係数法であった。(5)ニューラルネット(NN)法の銘柄選択効果は小さかったが、今回はシンプルなモデルで検証を行っており、有効性が高い合成方法に改良することは可能であろう。

(Abstract)

This study shows the relationship between the method of combining growth factors and the individual future stock returns. In this study, using growth metrics devised by Asness, Frazzini, and Pedersen (2019), 5 combining methods are compared. Five methods are (1) Equal Weight, (2) Principal Component Vector Weight, (3) Regression Coefficient Method, (4) Composite IC Maximization Method, (5) Neural Network Method. There are high correlations between combined growth factors, except for (5) Neural Network Method. And, Except for (5) Neural Network Method, growth factors have the positive relationship with future stock returns. Especially (3) Regression Coefficient Method has the strong predictability for stock returns compared to other methods. On the other hand, (5) Neural Network Method has weak predictability for future stock returns. In this study, A simple model was used on (5) Neural Network Method, (5) Neural Network Method has a lot of room for improvement.

1 はじめに

企業の将来の成長性に関する情報には、予想売上高の伸び率や予想利益の伸び率など様々なものがある。株式運用の実務では、利益成長率や、収益性の変化の情報を、将来の成長の代理変数とするケースも少なくない。これらは実務ではグロースファクターと呼ばれている。本稿は、複数のグロースファクターを取り上げて、それらの合成を行い、どのような合成方法が将来のリターンと関係があるのかを検証する。

代表的なグロースファクターとして、実務界では過去の実績利益成長率が使われることが少なくない。これまで高い利益成長を実現してきた企業は、良好な経営環境が背景にあるケースや、企業の優れた技術力や人的資本があるため、その持続期待から将来に向けた成長を見込むからである。こうした投資家の期待を背景に過去の成長率が高い企業は将来の株式リターンも高いことが期待される。しかし、実証研究の領域では、過去の利益成長率が将来の株式リターンと正の相関があることに否定的な研究が少なくない。代表的な研究には Fairfield, Sweeney and Yohn (1996) がある。同論文では、過去の成長率は将来の利益の一部を説明できるが、成長率が高すぎる場合は逆に減速する可能性があるとは指摘している。更に、Chan, Karceski and Lakonishok (2003) は過去の成長率は将来の利益の一部を説明できるが、成長率が高すぎる場合には、将来の成長率は減速する可能性があるとは指摘している。これらの研究は過去の高い成長率を実現してきた企業は、その反動から将来は成長率が低下する傾向があり、株式リターンもこうした成長率のリバーサルを反映して下落しているとするものである。

また、運用実務においては予想成長率もグロースファクターに用いられるケースも見られる。今期利益の予想成長率や売上高成長率などが、その代表的なものである。実証研究では過去の成長率の研究結果とは異なり、予想成長率と将来のリターンは正の相関があるとされるものがある。代表的なものとして Lettau and Ludvigson (2005) では、ビジネスサイクルを通じて予想配当成長率が期待リターンと正の相関があることを指摘している。配当成長率は利益成長率とも関係が強いため、予想成長率が高いと株式リターンが高いという学術的な根拠にもなる。

Asness, Frazzini and Pedersen (2019) は収益性、成長性、安全性などの面が高い企業のリターンから低い企業のリターンを引いた *quality-minus-junk (QMJ)* ファクターを考案している。その QMJ ファクターがリターンと正に有意な関係を示している。本稿は QMJ ファクターを構成する要素の 1 つのグロースファクターに着目して、我が国において株式リターンとの関係を検証して、更に、グロースファクターを構築する際の、合成方法について、いずれの方法が効果的となるかを検証する。その際に先行研究の指摘から予想利益を用いる成長性指標を用いる。

一般に運用実務界ではグロースファクターの構築は難しいとされている。今年度や来年度といった比較的近い将来の成長が、遠い将来の企業の成長と関連するとは限らないから

である。これが、グロースファクターが将来の株式リターンの予測につながりにくい理由とされる。しかし、本稿において、将来の株式リターンと関係があるファクター合成によりグロースファクターを算出できれば実務面への示唆にもつながるだろう。

本稿の構成は次の通りである。まず第2節では分析データを示す、ここではリターンとの関係を捉える検証方法も確認する。第3節では本稿で分析対象とする合成方法を示す。第4節で分析結果を示す。第5節のおわりにでは、まとめと今後の課題を示す。

2 データと検証方法

本稿は Asness, Frazzini and Pedersen (2019) で提示されたグロースファクターを構成する指標をベースとして、将来のリターンに対して効果的な合成方法を検証する。

2.1 分析に用いるグロース指標

本節では、分析に用いるグロース指標を示す。本稿で分析に用いるグロースファクターを構成する指標を表1にまとめている。

表1 グロースファクターを構成する指標

指標名	内容
$\Delta gpoa$	売上総利益／期首期末平均総資産－5年前の売上総利益／5年前時点の期首期末平均総資産
Δroe	来期予想純利益／期首自己資本－3年前の純利益／3年前の期首期末平均自己資本
Δroa	来期予想営業利益／期首総資産－3年前の営業利益／3年前の期首期末平均総資産
$\Delta cfoa$	CF／期首期末平均総資産－5年前のCF／5年前の期首期末平均総資産
$\Delta gmar$	売上総利益／売上高－5年前の売上総利益／5年前の売上高

(出所) Asness, Frazzini & Pedersen 論文をもとに筆者作成

本稿では Asness, Frazzini and Pedersen (2019) で取り上げられた5指標をベースに用いる。いずれも企業の収益率を代表する指標が5年前と比べてどれだけ改善しているかを見るものである。Asness, Frazzini and Pedersen (2019) では、指標に用いられる利益は全て直近で取得できる実績利益やキャッシュフローを用いている。このため収益性の改善としては5年前の収益性との比較を行っている。

しかし本稿では、 Δroe 、 Δroa で用いられる純利益と営業利益は直近で取得できる来期予想とする。これは、成長性に関する指標の算出に予想値を用いることで将来のリターンとの正の相関が確認される Lettau and Ludvigson (2005) の研究に依拠する。本稿で用いる純利益と営業利益は東洋経済新報社の予想値とする。そして、可能な限り将来の予想値を用いる趣旨から来期(2期先)予想値を用いる。その時点から5年前との収益性の比較を行うため、3年前の実績収益性との比較により指標を算出する。実績財務指標に関するデータは日本経済新聞社が提供するものを用いる。

Asness, Frazzini and Pedersen (2019)では、(1)式に示されるようにそれぞれの指標は利益

やキャッシュフローの変化を 5 年前の総資産，自己資本や売上高でデフレートしている．

$$\frac{\text{直近の利益など}-5 \text{ 年前の利益など}}{5 \text{ 年前の自己資本}} \quad (1)$$

同指標は変化率に近い指標となるためグロースファクターとして，より直観に合うものになる．ただ，Asness, Frazzini and Pedersen (2019) では，直近の利益には物価の変動などを考慮する観点でリスクフリー金利に対する超過利益を用いるなど，複雑な処理をしている．また，企業の合併などの処理も必要になる．本稿では分かり易さのためにシンプルに収益性の改善を用いる．

2.2 リターンとの関係の検証方法

本節では，グロースファクターとリターンとの関係を捉えるためのデータと検証方法を示す．本稿は，グロースファクターが将来のリターンとどの程度のあるかを，5 分位ポートフォリオの手法を用いて検証する．

分析対象ユニバースは TOPIX（東証株価指数）を構成する銘柄のうち金融業（東証 33 業種分類における銀行，証券，保険とその他金融）を除いたものとする．

分析サイクルは月次とする．グロースファクターに関しては，毎月末時点で明らかとなっている情報を用いて計算する．すなわち実績財務指標は決算発表後の月末に情報が更新される．予想利益については，毎月末時点で取得できる東洋経済新報社の予想値を用いる．

毎月末にグロースファクターをベースにする情報でランキングして，分析対象ユニバースのなかで銘柄数が等しくなるように 5 分位に分ける．そして，グロースファクターが低い順に Q1 から Q5 とする．またグロースファクターが高い分位（Q5）の銘柄群をロングし，グロースファクターが低い分位（Q1）の銘柄群をショートするロングショートポートフォリオ（Q5-Q1）も求める．分析に使うポートフォリオのリターンは等ウェイトとする．

また対象期間は 2012 年 1 月から 2025 年 2 月までの 158 ヶ月とする．

3 分析対象とするのグロースファクターの合成方法について

本稿では， $\Delta gpoa$ ， Δroe ， Δroa ， $\Delta cfoa$ ， $\Delta gmar$ の 5 指標を次の 5 つの手法により合成する．

- (1) 等ウェイト
- (2) 主成分ウェイト
- (3) 回帰係数法
- (4) 合成 IC 最大化法

(5) ニューラルネット (NN) 法

以下では、それぞれの手法に関する概要と実際のデータの使い方を示す。

3.1 等ウエイト

等ウエイトは $\Delta gpoa$, Δroe , Δroa , $\Delta cfoa$, $\Delta gmar$ を銘柄毎に単純平均するものである。実際に、単純平均をする際に、それぞれの情報について、(2) 式に示すようにユニバースでクロスセクションに Z 変換を行っている。それぞれの情報の平均が 0, 分散が 1 となるように基準化することで合成したファクターに対する個々の指標の影響度を等しくするためである。

$$(\text{Z 変換により}) \text{ 標準化した指標} = \frac{\text{指標値} - \text{ユニバースに該当する銘柄で計算した指標の平均値}}{\text{ユニバースに該当する銘柄で計算した指標の標準偏差}} \quad (2)$$

3.2 主成分ウエイト

主成分ウエイトは $\Delta gpoa$, Δroe , Δroa , $\Delta cfoa$, $\Delta gmar$ をユニバースでクロスセクションに主成分分析を行い、その第 1 主成分を参考にしたウエイトを用いてグロースファクターとするものである。実際には (2) 式で Z 変換した後に、主成分分析を行い第 1 主成分のウエイトベクトルを抽出する。そして、分析時点の月末まで過去 60 カ月平均した後に、対応する個々の標準化した指標と掛け合わせて合計した値をグロースファクターとする。

主成分分析による第 1 主成分を参考にする理由は、5 つの指標は成長性を代表とする変数であるため、第 1 主成分が潜在変数としてのグロースファクターと考えられるからである。ただし、ウエイトベクトルは過去 60 カ月の平均を用いている。これは、第 1 主成分のウエイトは毎月変動するため、ある程度の期間の平均値を用いて参考とするためのものとしている。

3.3 回帰係数法

回帰係数法は毎月、ユニバースをクロスセクションに (3) 式の回帰分析を行った係数を用いて合成ウエイトを決める方法である。被説明変数は当月のリターンで、説明変数は前月末時点における (2) 式で Z 変換後のグロース指標を用いる。

$$\begin{aligned} & \text{株式リターン}_{i,t} \\ &= a_t + b_t \Delta gpoa_{i,t-1} + c_t \Delta roe_{i,t-1} + d_t \Delta roa_{i,t-1} + e_t \Delta cfoa_{i,t-1} + f_t \Delta gmar_{i,t-1} + \varepsilon_{i,t} \quad (3) \end{aligned}$$

i は銘柄, t は時点, $a_t \sim f_t$: t 時点で回帰パラメータ, $\varepsilon_{i,t}$: i 銘柄の t 時点での残差項

$b_t \sim f_t$ は, t 時点のリターンに関して、5 つのグロースファクターの影響度合いを示す。実際に

は、それぞれの回帰係数を分析時点の月末まで過去 60 カ月平均した後に、負値のケースは 0 に置き換えて、合計が 1 となるようにウェイトに変換する。これを t 時点でのファクター合成ウェイトとする。

回帰係数の過去 60 カ月平均を用いている理由は、回帰係数の平均値は毎月変動するため、ある程度の期間の平均値を用いて参考とするためである。

直観的には、平均して回帰係数が大きい指標の合成ウェイトを高くする方法である。

3.4 合成 IC 最大化法

指標と株式リターンとの関係を捉えるものとして、クロスセクションに個別銘柄の指標の値と、将来の株式リターンとの間で相関係数を求める方法がある。運用実務界では IC (Information Coefficient) と呼ばれるものである。ここでは前月末時点での 5 つのグロースファクターと当月のリターンとの間でそれぞれ IC を求める。そして、それぞれの IC を分析時点の月末まで過去 60 カ月平均する。更に、(4) 式の最大化により w のグロースファクターの合成時のウェイトを求めるものが合成 IC 最大化である。

これにより当月末 (t 時点) の指標の合成ウェイトを決めるものである。

$$(IC) = \frac{w^t \overline{IC}}{\sqrt{w^t \rho w}} \quad (4)$$

w : グロースファクターの合成時のウェイト [$k \times 1$]

ρ : グロースファクターの相関係数行列 [$k \times k$]

$\overline{IC}$: グロースファクターの IC の列ベクトル [$k \times 1$]

k : 合成するファクター数

(4) 式は (5) 式の展開により求まるものである。

$$\begin{aligned} IC_x &= \frac{\sigma(r, x)}{\sigma(r)\sigma(x)} = \frac{\sigma(r, \sum w_k a_k)}{\sigma(r)(\sigma(\sum w_k a_k, \sum w_k a_k))^{1/2}} \\ &= \frac{\sum w_k \sigma(r, a_k)}{\sigma(r) \left[\sum_k \sum_l w_k w_l \sigma(a_k, a_l) \right]^{1/2}} \quad (5) \\ &= \frac{\sum w_k \sigma(r, a_k)}{\sigma(r) \left[\sum_k \sum_l w_k w_l \sigma(a_k) \sigma(a_l) \rho(a_k, a_l) \right]^{1/2}} \\ &= \frac{\sum w_k \sigma(r, a_k)}{\sigma(r) \cdot \sigma(a_k) \cdot \sigma(a_l)} \times \frac{1}{(w^t \rho w)^{1/2}} = \frac{w^t IC}{(w^t \rho w)^{1/2}} \end{aligned}$$

ICx: 合成したグロースファクターの IC

r : リターン, x : 合成ファクター, a : 個々のファクター

IC: 個々のファクターの IC 列ベクトル

w: グロースファクターの合成時のウェイト列ベクトル

この方法に関して直観的な解釈は、平均して IC が高い指標のウェイトを高めるが、IC が低くても他の指標と相関が低ければ、ウェイトが高まる傾向がある。

3.5 ニューラルネット (NN) 法

ニューラルネット法は毎月、前月末の 5 つの指標を入力変数、翌月のリターンを出力変数として機械学習を行いシンプルなニューラルネットのモデル化を行う。学習期間は過去 60 カ月間とする。その構築したモデルに当月の 5 つの指標を入力する形で将来のリターンを推計するものである。厳密には合成ファクターを推計するものではないが、予測する将来のリターンは合成ファクターが背後にあるものと考えられる。

本稿で用いるニューラルネットはシンプルなものとする。隠れ層を 2 層として、それぞれのレイヤーを 64 とする。モデルは複雑にする自由度は大きいですが、ここではシンプルな機械学習によるモデル化の効果がどの程度であるかを確認する目的がある。

3.6 合成方法間の違いについて

本節では (1) 等ウェイト、(2) 主成分ウェイト、(3) 回帰係数法、(4) 合成 IC 最大化法、(5) ニューラルネット (NN) 法の 5 つの方法で合成するグロースファクターがどのように違いがあるかに関して相関係数で概観する。2020 年 3 月～2025 年 2 月 (過去 60 カ月間) にそれぞれの合成手法で求めたグロースファクターの相関係数を示す (ピアソンの積率相関係数)。

表 2 グロースファクターの相関係数行列

	(1)等ウェイト	(2)主成分ウェイト	(3)回帰係数法	(4)合成IC最大化法	(5)NN法
(1)等ウェイト	1.00				
(2)主成分ウェイト	0.89	1.00			
(3)回帰係数法	0.69	0.83	1.00		
(4)合成IC最大化法	0.67	0.81	0.98	1.00	
(5)NN法	-0.03	-0.03	0.02	0.02	1.00

(注) 2020 年 3 月～2025 年 2 月の 60 カ月で求めたそれぞれの合成手法で求めたグロースファクター間のピアソン積率相関係数。

(5) ニューラルネット (NN) 法は他の 4 つの合成手法によるグロースファクターとほぼ無相関となっている。しかし、それ以外の (1) 等ウェイト、(2) 主成分ウェイト、(3) 回帰係数法、(4) 合成 IC 最大化法の 4 つの合成方法によるグロースファクターの間での相関係数はある程度高い水準の相関係数となっている。

(3) 回帰係数法と (4) 合成 IC 最大化法との相関係数は 0.98 と高い。これらの手法は、シンプルにリターンに対して、過去 60 カ月で有効性が高いファクターの合成ウエイトを高める点で共通するからである。

(1) 等ウエイト, (2) 主成分ウエイトの間の相関係数も 0.89 と高かった。これは第 1 主成分に対して 5 つの指標の寄与は概ね同程度となっているからと見られる。

(3) 回帰係数法, (4) 合成 IC 最大化法と (5) ニューラルネット (NN) 法はリターンとの関係をベースにウエイトを決定するものである。一方, (2) 主成分ウエイトは 5 つの指標の情報も最も効率的に集約させるという観点でのウエイト決定手法である。このため, ウエイト決定にリターンの情報は用いていない。しかし, (3) 回帰係数法, (4) 合成 IC 最大化法と (2) 主成分ウエイトの間では 0.8 と一定の水準の相関係数が示されている。

4 分析結果

分析結果に関しては, (1) 等ウエイト, (2) 主成分ウエイト, (3) 回帰係数法, (4) 合成 IC 最大化法, (5) ニューラルネット (NN) 法の 5 つの方法で合成するグロースファクターを月次サイクルで算出して, リターンとの関係を 5 分位ポートフォリオの手法で観察する。

検証に用いるグロースファクターは, 2011 年 12 月～2025 年 2 月までの月次ベースで算出される。これに対応して 2012 年 1 月～2025 年 2 月までの 158 カ月の期間で検証に用いる個別銘柄のリターンを用いる。

結果は表 3 に示される。Q1 から Q5 の表中の「値」は, それぞれの分位に該当する銘柄の等金額投資ポートフォリオの月次リターンから, ユニバースの等金額投資ポートフォリオの差 (超過リターン) を平均して年率換算したものである。またスプレッドは Q5 ポートフォリオのリターンから Q1 ポートフォリオのリターンを引いた値である。この値がプラスに大きいことは, グロースファクターが付された銘柄の将来リターンがプラスとなり, ネガティブなグロースファクターの銘柄の将来リターンがマイナスとなり銘柄選択効果が高いことを示す。

表 3 それぞれの合成手法によるグロースファクターの検証結果

	Q1(最低)		Q2		Q3		Q4		Q5(最高)		スプレッド(Q5-Q1)	
	値	t値	値	t値	値	t値	値	t値	値	t値	値	t値
(1)等ウエイト	0.10%	0.11	-0.50%	-0.85	0.11%	0.20	-0.24%	-0.49	0.53%	0.49	0.44%	0.27
(2)主成分ウエイト	0.11%	0.13	-0.01%	-0.03	-0.91%	-1.62 *	0.61%	1.29	0.20%	0.19	0.08%	0.05
(3)回帰係数法	-1.08%	-1.30 *	-0.42%	-0.64	-0.11%	-0.19	0.67%	0.78	0.93%	0.78	2.01%	1.19
(4)合成IC最大化法	-0.79%	-0.88	-0.88%	-1.33 *	0.02%	0.04	0.85%	1.64 *	0.80%	0.70	1.59%	0.94
(5)NN法	0.41%	0.55	-0.50%	-0.98	-0.61%	-1.12	0.38%	0.74	0.33%	0.44	-0.08%	-0.08

(注 1) 2012 年 1 月～2025 年 2 月までの検証。

(注 2) 5 分位ポートフォリオの月次サイクル検証。Q1 はファクターが最も低い (ネガティブサイド) のポートフォリオ, Q5 はファクターが最も高い (ポジティブサイド) のポートフォリオ。

(注 3) 表中の「値」は, それぞれの分位に該当する銘柄の等金額投資ポートフォリオ月次リターンから, ユニバースの等金額投資ポートフォリオの差 (超過リターン) を平均して年率換算したものの。

(注 4) スプレッドは Q5 ポートフォリオのリターンから Q1 ポートフォリオのリターンを引いた値。

(注 5) t 値は, 「値 (平均値)」が 0 から有意に離れているかの値。* は t 値が両側 20% で有意に 0 から離れている。

(5) ニューラルネット (NN) 法を除いた 4 つの手法で Q5-Q1 のスプレッド (リターン)

がプラスとなっている。このことは、グロースの合成ファクターが銘柄選択にある程度、有効に機能する可能性を示す。しかし、スプレッド（リターン）の（平均）値はそれほど高い水準ではなく、統計的には有意とはなっていない。

最も、効果的な合成方法は（3）回帰係数法である。統計的には有意とはならないが、スプレッド（リターン）の（平均）値が最も高い水準である。また、（4）合成IC最大化法の効果も準じている。これらのリターンとの関係をベースにウェイトを決定する方法が効果的であることが示される。

（1）等ウェイト、（2）主成分ウェイトはスプレッド（リターン）の（平均）値が余りたかくなかった。そして、（5）ニューラルネット（NN）法はスプレッド（リターン）の（平均）値がほぼ0となっている。今回はシンプルなニューラルネットのモデルで検証を行っている。更に、モデルに改良の余地は十分にあることや、（3）回帰係数法などのリターンとの関係でのウェイト決定をする手法が比較的效果が見られたことから、有効性が高い合成方法とすることは可能であろう。

5 おわりに

本稿は、複数のグロースファクターを取り上げて、それらの合成を行い、どのような合成方法が将来のリターンと関係があるのかを検証した。

検証方法に関して、まずは、Asness, Frazzini and Pedersen (2019) で提示された $\Delta gpoa$, Δroe , Δroa , $\Delta cfoa$, $\Delta gmar$ の指標を、予想値などを用いた修正を行い、我が国に適用して算出した。そして、（1）等ウェイト、（2）主成分ウェイト、（3）回帰係数法、（4）合成IC最大化法、（5）ニューラルネット（NN）法の5つの方法で合成するグロースファクターを月次サイクルで算出して、リターンとの関係を5分位ポートフォリオの手法で観察した。

その結果、グロースの合成ファクターが銘柄選択にある程度、有効に機能する可能性を示したものの、その銘柄選択効果は有意とはならなかった。合成ファクターの銘柄選択効果は $\Delta gpoa$, Δroe , Δroa , $\Delta cfoa$, $\Delta gmar$ の5つの指標の有効性にも依存するため、合成により効果を高めることに限界があるからだろう。

今回、検証した合成方法のうち最も効果的だったのは（3）回帰係数法であった。また、（4）合成IC最大化法の効果も高く、リターンとの関係をベースにウェイトを決定する方法が効果的であることが示された。

（5）ニューラルネット（NN）法の銘柄選択効果は小さかった。しかし今回はシンプルなニューラルネットのモデルで検証を行っており、（3）回帰係数法などのリターンとの関係でのウェイト決定をする手法が比較的效果が見られたことから、有効性が高い合成方法とすることは可能であろう。

5つの方法で合成するグロースファクターは互いに相関係数が高いものも見られた。しかし、実際のリターンとの関係の検証では、有効性に差も少なからず見られたことから、グロ

ースファクターを合成する際に、どの方法を用いるかは運用実務においても銘柄選択で重要なことが示された。

本稿を作成するにあたり、青山学院大学大学院国際マネジメント研究科 森田充教授、ニッセイアセットマネジメントの中田喜之氏より有益なコメントを頂いた。ここに記し、感謝申し上げる。本稿の内容は筆者らが所属する組織を代表するものではなく、全て個人的な見解である。また、当然のことながら、本稿における誤りは全て筆者の責に帰するものである。

(参考文献)

- Asness, C.S. A. Frazzini and L.H. Pedersen (2019) “Quality minus Junk,” *The Review of Accounting Studies* 24, 34–112.
- Chan, L.K.C. J. Karceski and J. Lakonishok (2003) “The Level and Persistence of Growth Rates,” *The Journal of Finance* 58(2) , 643–684.
- Fairfield, P.M. R.J. Sweeney and T.L.Yohn (1996) “Accounting Classification and the Predictive Content of Earnings,” *The Accounting Review* 71(3) , 337-355.
- Lettau, M. and S.C. Ludvigson (2005) “Expected Returns and Expected Dividend Growth,” *Journal of Financial Economics* 76(3) , 583-626.