技术脱钩

Monika BalodaA. Gary Anderson Graduate School of Management，加利福尼亚大学河滨分校

2023年3月31日

摘要

金融市场波动性是投资、期权定价和金融市场监管的重要依据；毫无疑问，科技是增长的引擎。在本项目中，我考察了过去十七年科技与非科技行业的共同变动。我将紧密的共同变动称为“耦合”，并指出，2015年之后，科技与非科技行业在水平值和波动率方面出现脱钩。我认为，新冠疫情冲击并非这一脱钩现象的成因。此外，我还表明，科技行业是经济其他部门增长的领先指标。我采用 ARIMA 建模和平稳性检验，对时间序列进行处理，以开展分析和检验。研究发现，科技行业指数服从 ARIMA(3,1,3) 模型，而非科技行业服从 ARIMA(2,1,4) 模型。我介绍了数据整理、预处理、缺失值处理和探索性数据分析（EDA）的步骤，并在必要之处讨论了本研究的优点与不足，以便正确解读研究结果。

Keywords: 时间序列，波动率，平稳性, 波动率，平稳性，ARIMA，外部有效性，金融共同变动 效性，金融共同变动 t. ARIMA，外部有效性，金融共同变动

arXiv:2304.00510v1 [q-fin.ST] 2 Apr 2023

1 引言

企业部门的两大支柱是金融和科技。自然地，这两个领域都是非常值得研究的主题。在本文中，我将深入探究二者交集中的一些见解。本文主要关注波动性模式。我提出了这样的问题：“科技行业是否比经济其他部门的波动性更高？”科技行业与经济其他部门的波动性模式是否随时间存在系统性差异？我还研究了这两个序列之间的相互关系，包括其中一个是否可以作为另一个的领先指标，以及其中一个是否对另一个构成格兰杰因果关系。本文涵盖2006年至2023年的时间段，约十七年。

动机– 假设有一位生活在这样一个世界中的人士A：唯一的收入来源是政府发放的薪水，而每天的生活支出为100美元。政府每年向A女士拨款36500美元。她有两种可能的收入流：第一种是每天获得100美元；第二种收入流具有不确定性，她可能某天获得500美元，也可能在另一天一无所获。她会选择哪一种收入流？显然，她会选择第一种，因为在第二种方案下，她的处境会更糟。用专业术语来说，可以表述为：“A女士偏好低波动率的收入流，而不是高波动率的收入流。”一些研究人员已经量化了金融市场波动性对劳动收入、经济增长和健康结果的影响。因此，波动率是一个重要的研究主题，也是投资、期权定价和金融市场监管中的重要输入。

经济学中有一种颇具影响力的理论，由 Paul Romer 教授（2018年诺贝尔经济学奖得主）提出，认为推动经济增长的是技术。如果没有技术进步，经济就会停滞，收入也将不再增长。经济学之外，人们普遍也对技术将如何影响生活感兴趣。尤其是我，对这一理论着迷，并决定在这个项目中对它进行检验（至少部分检验）。

结合波动率和技术这两个重要支柱，我决定研究科技行业的金融市场波动性，以及它与经济其他部门的关系。因此，我收集了纳斯达克100指数中科技行业指数收益率的数据。值得庆幸的是，纳斯达克100指数也提供非科技指数。这两条覆盖2006年至2023年各时期的日度时间序列构成了本文的基础。我在研究中遵循 James Hamilton（2020）所著的著名时间序列分析教材。纳斯达克100指数的 NDXT 指数是纳斯达克100指数中属于科技行业的公司的股票价格指数。我们将这条时间序列称为 y_t。同样，纳斯达克100指数的 NDXX 指数

是纳斯达克100指数中不属于科技行业的公司的股票价格指数。我们将这条序列称为 x_t。在第一节中，我检验时间序列 y_t 是否是时间序列 x_t 的领先指标。科技行业的具体定义等细节将在后续相关章节中说明。

具体研究问题：– 我的具体研究问题是："科技行业的波动率是否不同于经济其他部门的波动率？"为了进行有效比较，我检验了这两个时间序列的各种统计特征，例如均值、分位数、分布等。首先，我使用简单的方差分析检验，比较两个样本的波动率均值。随后，我们将数据按不同时期进行细分，以检验波动率关系是否在不同时期保持一致。我们发现，这种关系确实会随时期而变化。作为对这一分析的补充，我还使用格兰杰因果关系等标准时间序列工具，考察科技序列与非科技序列之间的相互关系。我还检验科技行业是否能够成为经济其他部门的领先指标，即科技行业今天发生的情况是否会在不久的将来出现在其他行业。统计检验的结果，例如技术是否驱动经济其他部门增长，可能会被不同的人作出不同解读。因此，明确写出具体的研究问题，能让我更容易向读者阐述自己的研究。

论文结构：– 在第 2 节中，我们将更深入地了解时间序列。本节将对主要分析所用数据进行整理、探索性数据分析和预处理。我们首先讨论时间序列状态为何不同，然后介绍数据来源和数据清洗。主要的探索性数据分析包括绘制图表、查看汇总统计量以及进行适当的 ARIMA 建模。随后，我们进行平稳性分析，并使序列达到平稳状态，以便后续分析。第 3 节和第 4 节是主要分析部分。我们在这两节中分析脱钩情况，先使用全样本，再将数据划分为若干时间区间。必要时，我们会讨论要点和局限性。在第 5 节中，我们进行补充分析，以检验技术是否引领该行业的其他部分。在第 5 节后半部分，我们回应有关外部效度的潜在质疑。最后，我们作出结论。

2 数据整理与探索性数据分析（EDA）

2.1 时间序列分析有什么特别之处?

数据集主要分为三种类型：截面数据、时间序列数据和面板数据。截面数据是在某一时间点对许多研究对象收集的数据，例如收集学生在2022年秋季学季的平均绩点。时间序列数据是针对单个研究对象，在多个（间隔相等的）时期内收集的数据，例如：从入学到毕业期间，我每个学季的平均绩点。面板数据结合了截面数据和时间序列数据，即在多个时期内收集许多研究对象的数据。

假设 i 是研究对象的下标，其取值从 $i = 1$ 到 $i = N$； t 是时间的下标，其取值从 $t = 1$ 到 $t = T$。下面我们写出三个回归方程，分别在三种不同的数据情形下建立简单线性回归模型。

$$\begin{aligned} \text{Cross-sectional} \quad & y_i = \beta_0 + \beta_1 x_i + \epsilon_i \\ \text{Time-series} \quad & y_t = \beta_0 + \beta_1 x_t + \epsilon_t \\ \text{Panel data} \quad & y_{it} = \beta_0 + \beta_1 x_{it} + \epsilon_{it} \end{aligned}$$

本项目这一部分的重点是时间序列。现在，我们来讨论一个核心问题：时间序列为何如此特别？截面数据和面板数据的主要假设是，数据独立同分布（*i.i.d.*）。这意味着一个数据点的抽取独立于另一个数据点，类似于 R 中的 $rnorm()$ 函数。然而，这一假设很难应用于时间序列数据。几乎在所有情况下，时间序列数据都不是 *i.i.d.*；它们与之前的取值存在某种依赖结构。由于这一关于数据的基本假设不成立，经典 OLS 估计理论便不再适用于时间序列数据。因此，我们无法使用传统线性回归方法，这就是时间序列特别之处。

鉴于我们无法使用经典的普通最小二乘估计技术，因此需要采用一些能够考虑时间序列数据结构所带来特殊问题的方法。因此，我们采用时间序列估计技术；关于时间序列模型的其余讨论，请参阅 Hamilton（2020）一书。

2.2 数据

我们的主要目标是考察科技行业与经济中其他行业之间的关系。因此，我们收集了反映这一关系的两个时间序列的数据。本节将介绍数据来源、所用变量的具体定义以及数据清洗过程。

2.2.1 数据来源

我们的数据涵盖2006年3月21日至2023年3月21日这一时间段。纳斯达克100指数中的科技指数于2006年2月22日首次设立。由于指数刚推出后可能会出现非理性波动，为避免这种情况，我们从一个月后的2006年3月21日开始收集数据。我们将数据收集截止日期定为2023年3月21日，以使时间跨度恰好达到17年。我们的数据按日频率收集。因此，对于给定的时间序列，我们总共有4297个数据点。我们从雅虎财经网站下载数据。

2.2.2 变量定义

我们收集了两类主要时间序列的信息：科技和非科技

1. **科技：纳斯达克100科技行业指数（NDXT）**：该指数根据行业分类基准（ICB）分类系统，将纳斯达克100指数中归类为科技行业的证券编制为等权重指数。2006年2月22日，纳斯达克100科技行业指数以1000.00为基准值开始运行。有关科技行业定义的更多信息，请参阅ICB定义此处。

2. **非科技：纳斯达克100非科技行业指数（NDXX）**：该指数根据行业分类基准（ICB）分类系统，将纳斯达克100指数中未被归类为技术行业的证券编制为等权重指数。与科技指数类似，该指数的基准值也设为 1000.00，起始日期为 2006年2月22日。

2.2.3 数据清洗与预处理

总体而言，数据提供方的网站已经对我们的数据进行了清洗和处理。我们的数据中几乎没有缺失值，因此无需进行缺失值处理。由于数据取自同一国家（美国）的同一股票市场指数，因此在本研究中，科技和非科技时间序列的交易日和经济因素均相同。因此，匹配相同的参考单位并不是问题。

具体而言，在 R Markdown笔记本中，我们展示了序列 y_t 在 4277 个观测值中有三个缺失值，而另一个序列 x_t 没有任何缺失值。因此，我们只删除这三个观测值，因为它们不会对分析结果造成显著影响。删除后，我们总共剩下 4274 个观测值或行。

数据清洗完成后，我们需要在 R 中对数据进行处理，以便将其作为时间序列对象进行分析。我们主要使用 R包xts 和zoo 进行数据处理，并在之后用于分析。首先，我们将两个时间序列的数据转换为数值形式。然后，我们将$Date$ 列读取为R中的日期对象。之后，我们将数据框对象中两列存储的两个时间序列指数转换为 R中的时间序列对象。现在 R软件会将这两个序列识别为时间序列对象。这样，我们就可以对这些序列应用专为时间序列对象设计的预构建函数。因此，我们可以开始使用函数进行数据探索和深入分析。接下来进入探索性数据分析（EDA）部分。

2.3 探索性数据分析（EDA）

为简便起见，从此处开始，我们将科技板块指数（NDXT）的时间序列称为 y_t ，将非科技指数（NDXX）的时间序列称为 x_t。在进行任何分析之前，本节先研究每个时间序列。我们将考察其平稳性、自回归阶数和移动平均阶数等属性。

2.3.1 工具

在本节中，我们简要概述用于数据探索的工具。这些工具通常不同于独立同分布（*i.i.d.*）数据情形，因此我认为在使用这些工具之前，有必要先简单介绍一下。

1. **自相关函数（ACF）：** 自相关函数（ACF）图展示了时间序列与其滞后值之间的相关性。它是了解时间序列中自相关程度的实用工具，也可用于确定自回归（AR）模型或移动平均（MA）模型的阶数。这里的自相关函数图以滞后阶数为横轴，以相关系数为纵轴。相关系数的取值范围为 -1 到 1，其中 1 表示完全正相关，-1 表示完全负相关。值为 0 则表示不存在相关性。

2. **偏自相关函数：** 在 James Hamilton 的《时间序列分析》一书中，第 2 章介绍了偏自相关函数（PACF），将其作为确定自回归（AR）模型阶数的方法。通过考察各滞后阶数对应的偏自相关的大小和显著性，PACF 可用于确定 AR 模型需要纳入多少个滞后阶数。某一特定滞后阶数对应的偏自相关较大，表明原始序列与该滞后值之间存在较强的相关性，这意味着应将该滞后阶数纳入 AR 模型。Hamilton 指出，ACF 和 PACF 都是确定 AR 模型阶数的有用工具，但不应孤立使用。两者需要结合起来，才能确定 AR 和 MA 模型的滞后阶数。

3. **协整检验：** 为了了解两个序列之间的相关性，我们会先进行简单的相关性分析。随后，为了评估长期关系并获得技术上的置信度，我会进行 Johanson协整检验。

4. **比较图：** 我们将两个序列绘制在一起，以观察它们的表现。这有助于我们了解两个序列在某个时间点具体发生了什么变化。为避免重复绘图并节省空间，我没有分别绘制两个序列。

5. **汇总统计量：** 我们绘制一张表格，展示五数概括、平均值、从起始日期到最后日期的总体变化，以及数据的变异情况。这张表有助于我们了解该序列的分布和总体百分比收益率。

2.3.2 科技指数（y_t）时间序列

本节将详细介绍科技指数。首先要说明的是，自该指数于2006年创立以来，我们就有它的数据。该指数的基准值为1000。我们在下表中列出该指数的五数概括和平均值： y_t 见表1 起始

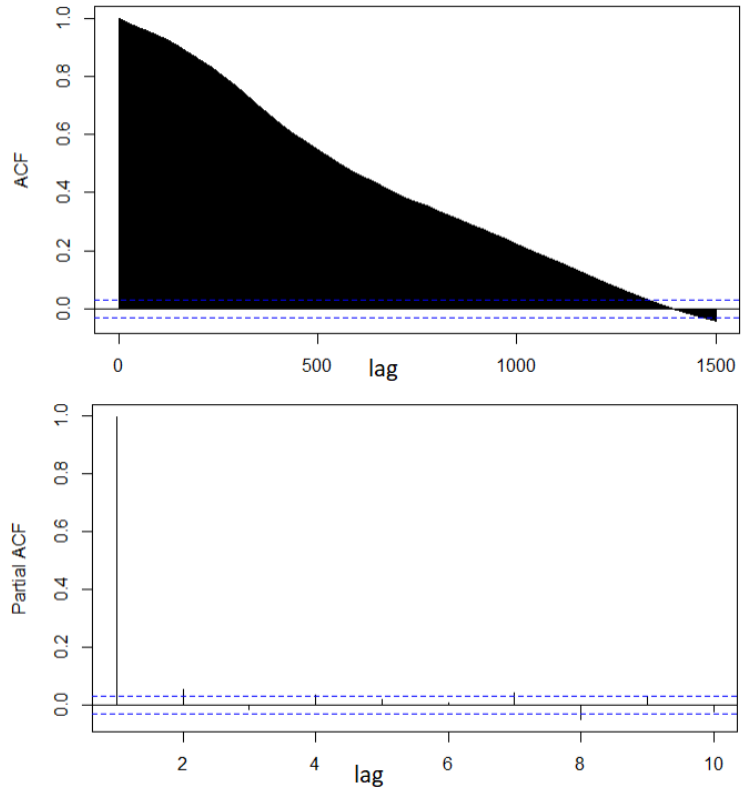
表1：科技指数序列（y_t）的汇总统计量

统计量	值	统计量	值
最小值	525.90	Mean	3029.00
第一四分位数	1194.20	最新值	6783.62
中位数	2138.40	起始值	1021.11
第三四分位数	4333.80	标准差	2330.62
最大值	9855.40	基准值	1000.00

值是指我们开始收集数据时的指数值，即2006年3月21日的指数值。该指数的最新值（2023年3月20日）为6783，这意味着过去17年间科技指数增长了约6倍，平均年回报率约为33%，表现十分亮眼。我们还可以看到该序列存在显著波动，其标准差几乎与平均值处于同一数量级。

为了更深入地了解该序列的时间依赖结构，我们绘制了图1中的自相关函数（ACF）和偏自相关函数（PACFs）。对于我们的序列 y_t，自相关函数并未降为零。严格来说，在考虑约1400个滞后阶数后，自相关函数才落入零附近的置信区间，与零的差异不再显著。然而，从建模角度看，处理如此多的滞后阶数既不容易，也不简约。由于自相关函数衰减得非常缓慢，该序列可能包含单位根成分，导致其在实际意义上呈非平稳。因此，在继续分析之前，我们需要对该序列进行单位根检验。目前我们尚未确定该序列的自回归阶数。单位根检验超出了探索性数据分析部分的范围，因此我们将其留待稍后的分析部分进行。

图 1：科技指数（序列 y_t）的自相关函数（ACF）和偏自相关函数



2.3.3 非科技指数（x_t）时间序列

本节将详细介绍我们的非科技指数，即序列 x_t。如前文数据部分所述，该非科技指数的正式名称为纳斯达克100指数中的除科技行业指数，以 NDXX 表示。下文将给出一张汇总表（表2），概览该序列在过去17年中的表现。我们注意到，基数

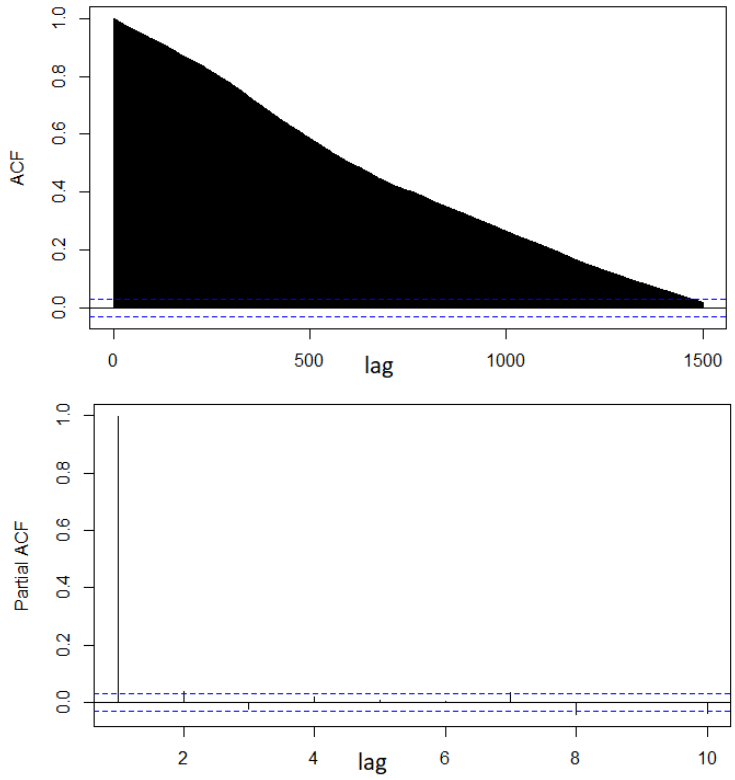
表 2：非科技指数序列（x_t）的汇总统计量

统计量	值	统计量	数值
最小值	561	Mean	1319
第一四分位数	1191	最新值	4675
中位数	2177	起始值	1027
第三四分位数	3055	标准差	1283
最大值	5360	基准值	1000

该指数的值为 1000，但我们在一个月后才开始收集数据，因此，我们的起始值指的是该指数在 2006年3月21日 的值。我们注意到，该指数的最新值为 4675，比起始值增长了 3.55 倍。如果将这一变化换算为平均年回报率，我们发现年回报率约为 21%。我们注意到，这一回报率低于科技指数 33% 的年回报率。我们还注意到，这一序列的波动率较低 y_t，因为这里的标准差是平均值的一半，而在序列 y_t 中，标准差约为均值的 75%。

为了揭示该序列的时间依赖模式，我们查看自相关函数和偏自相关函数。这两个图，即该序列的自相关函数和偏自相关函数图（图-2），与序列 y_t 的定性特征相似。我们注意到，该序列的自相关函数衰减得甚至比序列 y_t还慢。偏自相关函数在第一个滞后阶数便立即降为零。因此，结论与我们对序列 y_t所述的相似。我们需要先进行单位根检验，以确认该序列是否平稳。因此，剩余分析将在后续章节中展开。

图2：非科技指数（序列 x_t）的自相关函数（ACF）和偏自相关函数



2.3.4 同时分析两个时间序列

将这两个序列放在一起分析，可以深入了解它们之间的关系。本节将展示两张图和一项检验。首先，我们将两个时间序列绘制在同一张图中（图-3）。

可以看出，直到2016年前后，这两个序列都紧密交织在一起。此后，它们开始脱钩。新冠疫情冲击进一步扩大了这两个序列之间的脱钩。两个序列如此紧密的共同变动，直接表明它们可能存在很强的相关性。

为了观察它们之间的交叉相关性，我们绘制了一幅图（图-4）。我们将最大滞后阶数设为1000，这意味着要计算两个序列当前值与其第1000阶滞后值之间的交叉相关性。我们注意到，相关系数的衰减非常缓慢，与各个序列的自相关函数相似。这幅图表明，1000个交易日前科技指数的变化会影响今天的非科技指数。这一说法看起来很容易让人相信。但其中可能存在伪相关。我们需要检验 x_t 与 y_t 序列之间的长期关系。

分析时间序列数据时，伪相关是一个值得关注的问题，因为许多经济和金融变量彼此高度相关，即使它们之间并不存在因果关系。这可能是共同外部因素影响所致，也可能是因为这些变量非平稳，且呈现彼此无关的趋势。另一方面，协整是时间序列分析中的一个重要概念，因为它有助于识别非平稳变量之间的长期关系。Hamilton 强调，在估计回归模型之前进行协整检验的重要性，因为不这样做可能导致伪回归和错误推断。

Hamilton（2020）还讨论了多种协整检验方法，包括 Engle-Granger两步法和 Johansen方法。这些方法通过检验变量之间是否存在共同随机趋势，帮助判断变量之间是否存在有意义的长期关系。因此，我们在此进行协整检验。此处，我们仅报告作出判断所需的检验统计量和临界值（表-3），为简化呈现，省略 Johansen检验结果的其余细节。该

图 3：科技（序列 y）和非科技（序列 y）指数随时间的变化图

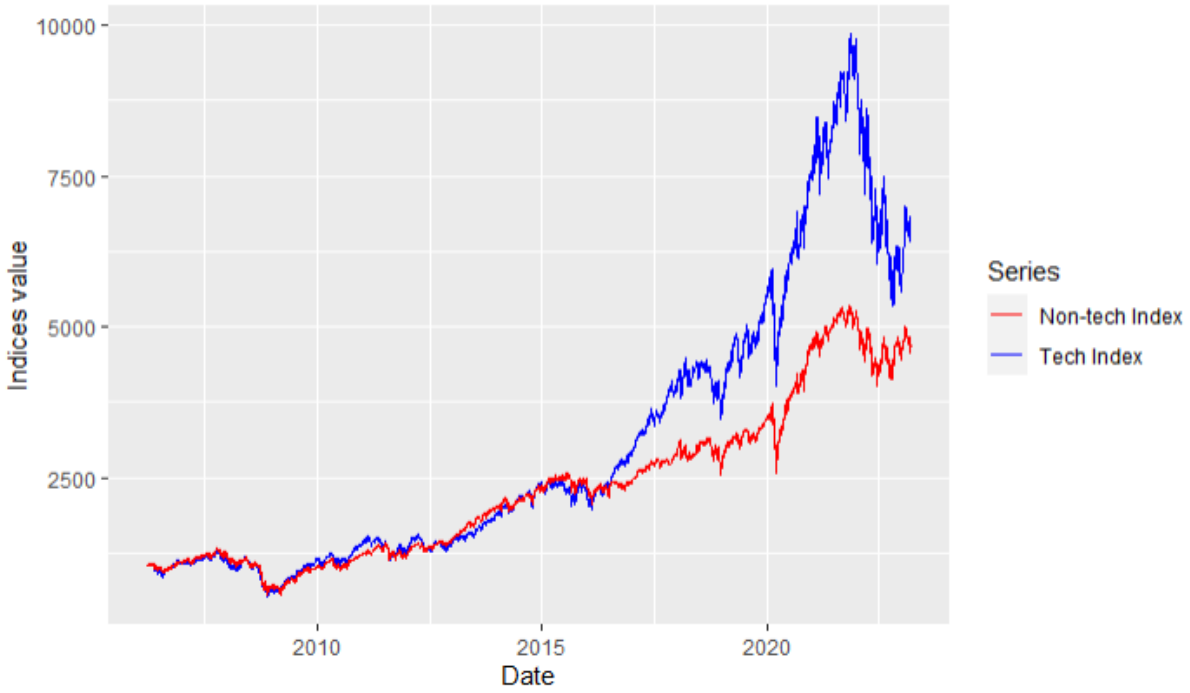
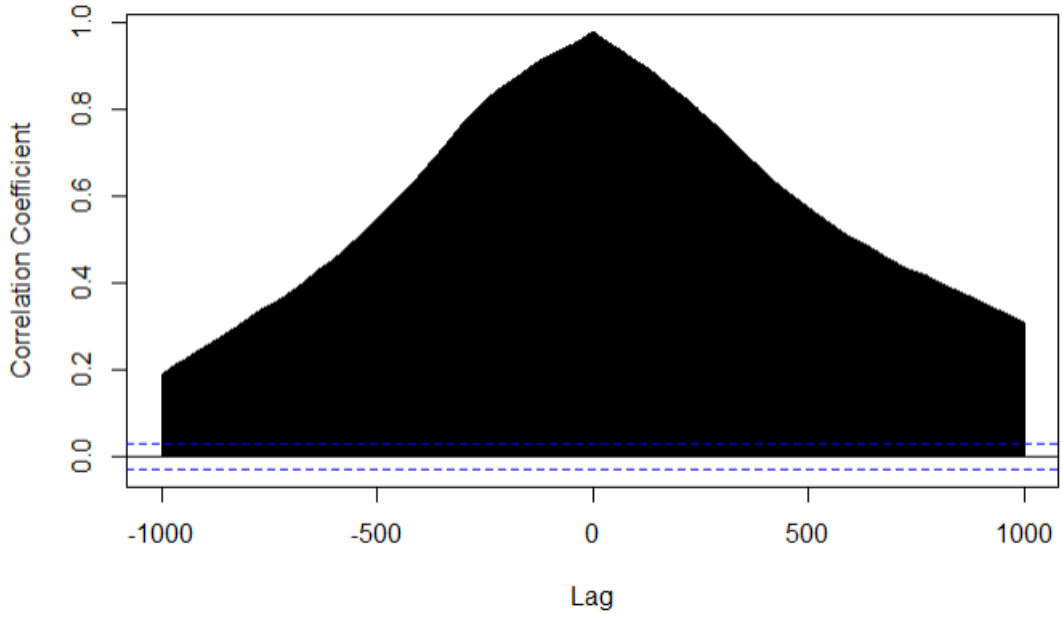


图 4：科技（y）与非科技（x）指数之间截至滞后阶数 1000 的互相关



Johansen协整检验通过 R 中的$ca.jo()$ 函数实现。原假设为：

H_0：系统中的变量之间不存在协整

换言之，原假设认为，不存在由这些变量构成的平稳线性组合，且这些变量之间不存在长期关系。

表 3：Johansen协整检验统计量及检验的临界值

阶数	检验统计量	10% 临界值	5%	1%
$r <= 1$	0.0	6.50	8.18	11.65
$r = 0$	3.6	15.66	17.95	23.52

结果解读：为了进行协整检验，两个序列必须是平稳的。但在本例中，我们并不确定它们是否平稳。假设 y_t 和 x_t 都是平稳的，那么该检验统计量（=3.6）小于 1%、5% 和 10% 显著性水平下的临界值，这意味着我们无法拒绝原假设。也就是说，不存在协整。因此，我们得出结论：没有证据表明序列 y_t 与序列 x_t之间存在协整或长期关系。由于不存在协整，我们无法断定这两个序列之间存在长期关系。但交叉相关图显示了相反的情况。不过，这一切都以两个序列均为平稳序列为前提；由于我们尚未检验这一假设，结论可能有误。因此，在得出任何结论之前，我们需要进行详细的平稳性分析。

2.3.5 探索性数据分析的要点

在本节中，我们进一步了解了时间序列。现在，我们知道它们在过去17年中的波动率和分布表现。我们还考察了两个变量之间的交叉关系。主要结论是，这两个时间序列很可能都是非平稳的。通过互相关和协整检验，我们进一步确认了进行平稳性分析的必要性。请注意，由于我们不知道 x_t 和 y_t 是否存在协整关系，因此协整检验的结果可能并不有效。

2.4 平稳性分析

该领域的许多基本结果和技术都以平稳性为前提，因此，违反这一假设会使这些方法难以正确应用。确保时间序列平稳，是分析时间序列数据的关键步骤，有助于避免建模和推断中常见的陷阱与错误。

在探索性数据分析部分，我们发现有必要确认我们的时间序列（y_t 和 x_t）是否平稳。若缺乏这一了解，后续分析可能都不正确。本节首先进行检验，以判断时间序列是否平稳。如果发现它们非平稳，我们就采用适当的方法将其转换为平稳时间序列。如果存在确定性时间趋势，我们就进行去趋势处理；另一方面，如果存在随机趋势，则进行差分。

2.4.1 什么是时间序列的平稳性

简而言之，平稳时间序列是指其均值、方差和协方差等统计性质随时间保持不变的序列。平稳性有多种定义，例如强平稳性、弱平稳性或协方差平稳性等。不过，文献中主要采用弱平稳性的概念。下文将对此进行定义。如果时间序列 y_t 满足以下条件，我们就称其为弱平稳或协方差平稳：

1. $\mathbb{E}(y_t) = \mu$：序列的均值不随时间变化。
2. $Var(y_t) = \sigma_y^2 < \infty$：序列的方差有限且不随时间变化。
3. $Cov(y_t, y_{t-s}) = \gamma(s)$：任意两个时间点的项之间的协方差仅取决于这两个点之间的时间差，而不取决于绝对时间。

所以，基本上这三个性质都不随时间变化。换句话说，我们可以说，对所有 i，$\mathbb{E}(y_t) = \mathbb{E}(y_{t+i}) = \mu$。此外，$Cov(y_1, y_2) = Cov(y_2, y_3) = Cov(y_{99}, y_{100})$。

2.4.2 为什么要关注平稳性?

定义了平稳性之后，接下来我将讨论为什么它是一种良好的性质，以及我们为什么要关注它。原因有很多，但我想重点介绍三个主要原因。首先，平稳性使序列的行为保持一致且可预测，从而更容易进行建模和分析。其次，许多标准时间序列模型，例如自回归积分滑动平均（ARIMA）模型，都假设序列具有平稳性。这些模型广泛应用于预测和其他领域，因此在应用它们之前，确保底层数据是平稳的十分重要。平稳性之所以重要的第三个原因是，非平稳时间序列可能会表现出伪相关，从而导致误导性的结论。例如，如果两个非平稳时间序列看起来高度相关，这可能仅仅是因为它们都随时间呈上升趋势，而非因为这两个序列之间确实存在关系。

2.4.3 平稳性检验

考虑以下简单的一阶自回归模型时间序列模型:

$$y_t = \alpha + \beta_1 y_{t-1} + \epsilon_t$$

系数 β_1 表示 y_{t-1} 对 y_t的边际影响。如果 $|\beta_1| < 1$，那么滞后阶数 项对当前时间序列的影响会随时间逐渐消失，因此我们称该序列为平稳序列。但如果不满足这一条件，则称该序列为非平稳序列。如果 $|\beta_1| = 1$，那么该序列是非平稳的，我们称其存在单位根。本节的目标是判断这个 beta 是否显著不同于 1。这是一个一阶自回归模型的简单示例，而现实中的时间序列模型可能比这复杂得多。在进行单位根检验时，我们并不假设序列遵循一阶自回归模型；这里的讨论仅用于说明。

我们使用增广迪基-富勒检验（ADF检验）来检验两个序列中是否存在单位根。ADF检验的原假设是:

$$H_0 : \text{Series has a unit root hence is non-stationary}$$
$$H_1 : \text{Series is stationary}$$

因此，如果我们发现*p*值 大于 0.05，那么在 95% 的显著性水平下，我们无法拒绝原假设。这意味着我们的序列存在单位根，因此不是平稳的。结果

表4: 平稳性增广迪基－富勒检验结果

时间序列	检验统计量	p值
科技（y_t）	-2.11	0.53
非科技（x_t）	-2.48	0.37

结果显示，*p*值 大于 0.05，因此我们无法拒绝两个序列均为非平稳的原假设。因此，这两个序列都不是平稳的。因此，我们在探索性数据分析部分看到的相关性不可信。

2.4.4 将我们的序列变换为平稳序列

为了消除原始序列中的单位根，我们生成一个一阶差分时间序列。一阶差分序列（Δy_t）通过用当前时期的值减去滞后一个时期的值生成。也就是说:

$$\Delta y_t = y_t - y_{t-1} \qquad \text{and} \qquad \Delta x_t = x_t - x_{t-1}$$

由于一阶差分时间序列减去了滞后一个时期的值，因此不存在 Δy_1 ，因为我们没有 y_0。因此，进行一阶差分时会产生一个缺失值。因此，我们需要删除一个观测值，以便进行进一步分析。完成后，我们将检验一阶差分后的变换序列是否平稳。

我们再次对变换后的序列进行增广迪基-富勒检验，以检查其平稳性。结果如下（表-5）：结果表明，我们注意到两个一阶差分序列Δy_t 和 Δx_t 在 99% 的置信水平下均为平稳序列。换言之，我们有超过 99% 的置信度认为，一阶差分序列 Δy_t 是平稳的。同样的结论也适用于 Δx_t。现在，既然我们的序列是平稳的，就可以应用常用的时间序列模型。

表5：变换后的序列平稳性的增广迪基－富勒检验结果

时间序列	检验统计量	p值
一阶差分后的科技(Δy_t)	-16.824	< 0.01
一阶差分后的非科技 (Δx_t)	-16.392	< 0.01

2.4.5 合适的时间序列建模：ARIMA 模型

了解序列的建模结构总有助于我们进行分析。这就像是在掌握一些相关信息的情况下处理问题，而不是在黑暗中盲目摸索。因此，我们继续确定变换后时间序列中的自回归阶数和移动平均阶数。

为确定变换后的序列的阶数，我们使用 R 中的内置函数。可直接给出序列 ARIMA 阶数的函数是 $auto.arima$()。点击 R 官方网站上的此处可查看该方法的详细文档。我们使用 $auto.arima$ 函数获取变换后的序列和原始序列的自回归阶数与滑动平均阶数。结果列于表6

表 6：使用 R 的 $auto.arima$ 函数确定时间序列的 ARIMA 阶数

时间序列	自回归阶数	差分阶数	移动平均阶数
科技 (y_t)	3	1	3
非科技 (x_t)	2	1	4
一阶差分后的科技 (Δy_t)	3	0	3
一阶差分后的非科技 (Δx_t)	2	0	2

在表格 -6中，自回归阶数表示一个序列依赖于自身多少个滞后项。I阶数表示单整阶数，即时间序列中单位根的数量。如果单位根数量或差分阶数为零，则该序列被称为平稳序列。滑动平均阶数说明了误差项的结构。滑动平均阶数等于零意味着误差项是白噪声。

我们注意到，原始的 y_t 和 x_t 序列的差分阶数为 1，而变换后的序列的差分阶数为 0。因此，我们可以确认此前的发现：两个原始序列各自都含有一个单位根。通过替代方法验证我们的发现，使我们对结果更有信心。

2.4.6 平稳性分析要点

本节首先讨论平稳性为何重要及其定义，然后介绍如何检验平稳性。通过实施平稳性检验，我们发现科技指数和非科技指数这两个序列均为非平稳序列。接下来，我们对序列进行变换，使其达到平稳。我们注意到，两个序列在进行一阶差分后都变为平稳序列。随后，我们使用 R 中另一个内置函数确认了这一发现。

最后，本节指出，科技指数（y_t）遵循 ARIMA(3,1,3) 模型，而非科技指数（x_t）遵循 ARIMA(2,1,4) 模型。

2.5 本次探索性数据分析的要点

这次探索性时间序列分析让我们获得了许多深刻见解。我意识到，在着手建立主要模型之前，需要进行大量预处理。以下几点总结了我的收获：

1. 科技指数序列（y_t）符合 ARIMA(3,1,3) 模型。另一方面，非科技指数符合 ARIMA(2,1,4) 模型。I =1 阶数意味着这两个序列都是非平稳的，但经过一阶差分后便会变为平稳序列。2. 科技（y_t）与非科技（x_t）指数之间的关系十分密切，但我们观察到，2016 年后两者出现脱钩，并在 2019 年的新冠疫情冲击下进一步扩大。3. 科技指数序列在 2016 年似乎出现了结构突变，并在 2020 年因新冠疫情冲击而进一步扩大。

本节为后续分析铺路。下一节中，我将更详细地分析波动性模式。此外，我还会进行一些补充分析，以支持主要分析。

3 水平值下的技术脱钩

正如前几节所述，我们使用的科技指数和非科技指数于2006年首次问世。两者的基准值均为1000。本节将追溯它们随时间的演变。具体而言，我们希望确认这两个时间序列是否在某个特定时间点或时期彼此脱钩。

我们已经看到，科技指数序列和非科技指数序列均为非平稳序列，且各有一个单位根。因此，我们通过一阶差分将其转换为平稳序列。本节分析将使用这一变换后的序列。

3.1 使用全样本 t检验水平值下的脱钩

3.1.1 检验程序

检验耦合是指判断两个序列是否足够接近。如果在某一时间段内发现它们的水平值存在统计显著差异，我们就称其脱钩。这里我们采用基本的 t检验，检查两个指数的均值是否存在显著差异。假设科技指数的均值为 μ_y ，非科技指数的均值为 μ_x。那么我们的原假设为 $\mu_y = \mu_x$。为进行简单的 t检验，我们计算两个序列之差，并检验其均值是否等于零。也就是说，我们的假设为：

$$\begin{aligned} H_0 \quad & \mu_y - \mu_x = 0 \\ H_1 \quad & \mu_y - \mu_x \neq 0 \end{aligned}$$

我们检验两个序列之差是否等于零这一原假设，并以差值不为零作为备择假设。如果能够拒绝原假设，就可以说这两个序列在水平值上并未耦合。

结果与推论 我们在表格中报告t统计量及对应的p值——7。

表7：一阶差分时间序列水平值相等性检验（全样本）

时间序列	t统计量	p值
$\Delta y - \Delta x$	0.6951	0.487

结果表明，考虑整个样本时，我们无法拒绝原假设。这些结果支持原假设，其基本含义是，科技指数与非科技指数的总体水平值之间没有显著差异。

3.2 分解时间区间内水平值的脱钩检验

在本部分中，我们将数据的整个时间跨度划分为五个部分，并尽可能使各部分的大小相等。下文将说明如何划分不同的时间区间，并报告相应结果。

3.2.1 多个时期的划分

在本节中，我们将数据集划分为不同部分。我们将数据分为四个部分，分别涵盖不同的数据点。第一时期涵盖2006年3月至2010年2月的观测值，第二部分涵盖2010年3月至2015年2月，第三部分涵盖2015年4月至2020年3月12日，最后一部分涵盖2020年1月20日之后至2023年3月的时间。我们选择一个特定日期将数据划分为第三和第四部分，因为根据疾病控制中心 网站，美国首例新冠病例出现在这一天。我们选择该日期将数据分为第三和第四部分。我们使用2020年3月12日进行敏感性分析。2020年3月12日是美国首次颁布居家令的日期。将数据划分为四个部分后，我们进行t检验，比较两个序列中波动率的均值。我们进一步将第四部分分为两部分：我们将2020年1月20日至2022年3月的时期称为新冠疫情时期。2022年3月之后，美国的第三波疫情结束了 [CDC参考资料],因此，我们将此后的时期称为后新冠时期。

3.2.2 结果与推论

我们对科技指数和非科技指数进行平稳变换，然后计算二者之差以检验耦合。下表-8 报告了多个时期的假设检验结果。

表8：时间序列水平值相等性检验（分解区间）

时间段	t统计量	p值
全球金融危机（GFC）：2006年3月至2010年2月	0.366	0.715
全球金融危机后：2010年3月至2015年2月	-0.452	0.651
新冠疫情前：2015年3月至1月20日，2020	2.299	*0.023*
新冠疫情：1月20日，2020年至2022年3月	0.567	0.571
后新冠时期：2022年3月至2023年3月	-0.837	0.403
分为两个阶段		
上半期：2006年3月至2015年2月	-0.135	0.893
下半期：2015年3月至2023年3月	0.718	0.473

根据这些结果，可以得出以下推论：

- 2006年至2015年间，科技指数与非科技指数呈耦合关系。全球金融危机未能打破这种耦合关系。

- 新冠疫情前时期（2015年至2020年），经济中的科技部门与非科技部门脱钩。两个部门的指数水平在95%置信水平下存在显著差异。具体而言，我们可以在95%置信水平下认为，新冠疫情前时期科技指数水平高于非科技指数。

- 与普遍看法相反，新冠疫情时期并未促成脱钩。

3.3 要点

在大部分时期，科技行业与非科技行业紧密耦合。如果对均值水平的差异进行统计检验，那么在全样本中，我们无法拒绝两条序列相近这一原假设。但如果将样本分为若干部分，我们就能看到这两个行业的脱钩。2015年至2020年的新冠疫情前时期，是科技与非科技行业开始出现脱钩的时期。新冠肺炎和全球金融危机似乎都没有对科技序列与非科技序列的紧密共同变动产生足够大的影响。

4 波动率脱钩

本节是本文的核心内容。我首先讨论波动率度量的构建，然后分析其时间序列性质。接着，我们对时间序列进行处理，使其达到平稳状态，以便应用标准的时间序列检验。

4.1 波动率序列：构建、建模与预处理 g

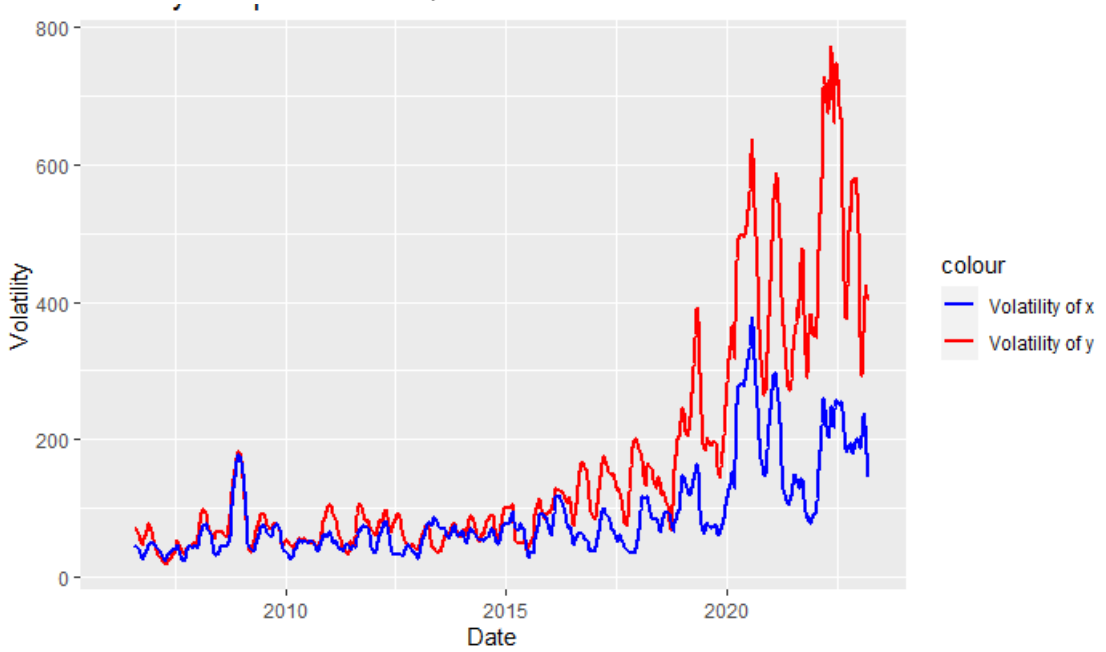
4.1.1 定义波动率

波动率用于衡量时间序列的起伏。换言之，序列的离散程度可以很好地反映其起伏情况。标准差就是一种这样的度量。我们使用滚动窗口法计算序列的标准差，并将其称为波动率度量。这种度量方法在相关文献中已是标准做法。以下步骤说明波动率的构建过程：

- 步骤 1：选择窗口大小——第一步是选择窗口大小，它决定了用于计算波动率度量的历史收益率数量。我们将窗口大小设为 100，即 100 个交易日，约为 4 个月。

- 步骤 2：计算收益率– 接下来，计算资产在窗口期内的收益率。收益率通常按窗口期内价格的百分比变化计算。

图 5：科技序列（y_t）和非科技序列（x_t）的波动率



- 步骤 3：计算标准差– 计算窗口期内收益率的标准差。这就是该期间的波动率指标。
- 步骤-4：移动窗口——将窗口向前移动一天，并重复步骤 2 和 3。这样就能得到下一个窗口期的波动率测度。
- 步骤-5：重复——继续向前移动窗口并重新计算波动率测度，直到覆盖整个关注的时间段。

我们选择的窗口大小具有一定的任意性。一般而言，较大的滚动窗口能够得到更稳定、更平滑的波动率估计，但代价是可能无法捕捉波动率的短期变化。另一方面，较小的滚动窗口对波动率短期变化的响应更灵敏，但代价是波动率估计中的噪声会增加，也可能变得不稳定。由于我们的分析着眼于长期（17年），采用100个交易日的滚动窗口是合理的，这在日历时间上约为四个月。之后，我们通过比较不同窗口大小得到的波动率度量，进行敏感性分析，以比较定性结果。

由于我们使用的窗口大小为100，因此会损失100个数据点，因为最初的观测值没有可用的前100个数值来构成窗口，因而不会为这些数据点计算波动率度量。不过请注意，对于其余每个观测值，都有一个对应的波动率数据点。因此，波动率序列的总数将比原始序列中的观测值少100个。在接下来的讨论中，我们将科技指数的波动率序列称为$vol\ y$，将经济指数其他部门的波动率序列称为$vol\ x$。

4.1.2 波动率时间序列建模

在讨论平稳性时，我们了解到平稳序列的重要性。基本上，为了应用大多数时间序列函数，我们需要将构建的波动率序列转换为平稳序列。在探讨波动率序列是否平稳之前，我们先将两个波动率序列绘制在时间轴上。

从观察结果来看，该序列似乎并不平稳。为了正式确认这一判断，我们进行了统计检验。在表-9中，我们描述了适用于这两个波动率序列的时间序列模型。

我们注意到，这两个波动率序列都是非平稳的，且均为一阶单整。本节最后指出，科技指数波动率 vol y 遵循 ARIMA(1,1,2) 模型，非科技指数波动率 vol x 遵循 ARIMA(3,1,3)。

表 9：使用 R 的$auto.arima$ 函数确定波动率时间序列的 ARIMA 阶数

时间序列	自回归阶数	差分阶数	移动平均阶数
科技指数波动率（波动率 y）	1	1	2
非科技指数波动率（vol x）	3	1	3

4.1.3 使波动率序列平稳

在上一小节中，我们注意到这两个波动率序列各有一个单位根。因此，使其平稳的一个直接方法是进行一阶差分。在探索性数据分析部分处理序列 y_t 和 x_t 时，我们已经这样做了。

表10：一阶差分波动率时间序列的 ARIMA 阶数

时间序列	自回归阶数	差分阶数	移动平均阶数
一阶差分波动率 y（Δ波动率 y）	1	0	2
一阶差分波动率 x（Δ波动率 x）	3	0	3

对波动率序列进行一阶差分后，我们进行增广迪基-富勒检验（ADF检验），以检查变换后的序列现在是否平稳。对于这两个序列，在 99% 置信度下，我们可以拒绝序列为非平稳的原假设。因此，变换后的序列是平稳的。

4.2 全样本上的简单 t 检验

4.2.1 检验程序

一个简单的 t检验比较两个样本的均值。假设序列 vol y 的平均波动率为 $\mu_{vol\ y}$，序列 vol y 的平均波动率为 $\mu_{vol\ y}$。我们的 t检验假设为:

$$H_0: \quad \mu_{vol_y} = \mu_{vol_x}$$
$$H_1: \quad \mu_{vol_y} \neq \mu_{vol_x}$$

检验该假设的另一种方法是直接计算两个序列之差，并检验新序列的均值是否等于零。也就是说，我们的原假设为:

$$H_0: \quad \mu_{vol_diff} = \mu_{vol_y} - \mu_{vol_x} = 0$$

由于 t检验的假设要求数据是平稳的，因此我们使用了一阶差分波动率序列。这是因为原始波动率序列是非平稳的，不满足 t检验的假设，因此可能会产生错误结果。因此，在检验中，vol y 指的是一阶差分波动率 vol y。

4.2.2 结果与推论

我们在表格中报告了 t统计量及相应的 p值—11。我们观察到无法拒绝

Ta表 11：一阶差分波动率时间序列的均值相等性检验（全样本 ）

时间序列	t统计量	p值
一阶差分波动率 y - 一阶差分波动率 x	1.551	0.1209

均值差异不为零的原假设，在95%置信水平下对两个波动率序列进行检验。因此，我们得出结论：在全样本中，科技指数与非科技指数的波动率没有显著差异。

4.3 分解时间段检验

我们使用前文讨论过的相同时间区间。本节报告波动率的检验结果。与此前对全样本进行的简单检验一样，我们使用波动率变换序列的一阶差分进行检验

表1: 一阶差分波动率时间序列均值相等性检验（分解后的时间段 d)

时间段	t统计量	p值
全球金融危机（GFC）：2006年3月至2010年2月	-0.765	0.4446
全球金融危机后：2010年3月至2015年2月	-0.105	0.9167
新冠疫情前：2015年3月至1月20日 , 2020	2.623	*0.0088*
新冠疫情：1月20日, 2020年至2022年3月	3.674	*0.0003*
后新冠时期：2022年3月至2023年3月	-2.050	*0.0414*
分为两个阶段		
上半期：2006年3月至2015年2月	-0.507	0.6121
下半期：2015年3月至2023年3月	1.686	0.0919

。为简洁起见，此处不再赘述。
我们从多个时期的检验中得出了有趣的推论。以下要点总结了我们的发现：

1. 我们注意到，如果将全部17年作为一个整体来看，科技指数与非科技指数的波动率并无差异。但如果更细致地考察不同水平值下的情况，不同时期的结果则存在显著异质性。2. 在2015年至2020年期间，科技行业的波动率显著高于经济其他部门。可以说，在这一特定时期，就波动率而言，科技行业与经济其他部门出现了脱钩。3. 我们注意到，新冠疫情时期大幅加剧了这种脱钩。4. 然而，后新冠时期这一波动率差距有所缩小，这主要是因为经济其他部门的波动率上升，而非科技行业序列的波动率下降。5. 如果将整个样本划分为两个样本，那么后半段的特点是科技行业波动率高于经济其他部门，且置信度超过90%。

4.4 波动率分析的要点

简要概括要点如下：

- 2015年之后，科技行业指数的波动率显著高于经济其他部门。我们将此称为科技行业与经济其他部门之间的波动率脱钩。
- 我们所说的技术脱钩 并非源于新冠疫情效应。不过，我们注意到，新冠肺炎加剧了这种脱钩。
- 我们还注意到，后新冠疫情时期非科技行业波动率上升，缩小了波动率差距。
- 总体而言，2015年之后的时期以波动率上升为特征，尤其是科技行业推动了这一趋势。非科技行业随后也加入了这一趋势。

5 补充分析

5.1 技术是否引领增长?

经济学中有一种颇具影响力的理论认为，技术驱动经济增长。相关领域的重要研究论文包括2018年诺贝尔经济学奖得主保罗·罗默的研究成果。在本节中，我们旨在使用时间序列建模来检验这一理论。为了实际实施这一检验，我们将纳斯达克100指数中上市的顶尖科技公司的股票收益定义为技术。同样地，我们将纳斯达克100指数中其余的非科技公司定义为经济其他部门。本节的其余部分将进一步说明相关技术细节。

5.1.1 模型

完成所有预处理并使序列平稳后，我们现在可以应用时间序列中的标准函数了。请注意，如果不使序列平稳，我们将无法使用这一模型。由于所有预处理工作都已完成，本节对我们而言会非常简短。我们先介绍该模型，然后讨论推论。

我们的任务是检验科技指数序列 y_t 是否领先于非科技指数 x_t 序列。假设该序列 y_t 领先于 x_t k 个时期。按照 Harvey（2020）所述的领先指标时间序列模型，我们基本上需要估计以下方程：

$$\Delta x_t = \beta_0 + \beta_1 \Delta y_{t-1} + \beta_2 \Delta y_{t-2} + ... + \beta_p \Delta y_{t-p} + \epsilon_t \tag{1}$$

这里，我们主要关注的系数是 β向量。如果该向量 β 显著异于零，那么我们可以说科技指数领先于非科技指数。因此，我们可以将原假设表述为：

$$H_0: \quad \beta_1 = \beta_2 = ... = \beta_p = 0$$

注意，我们不能直接在模型中使用 y_t 或 x_t ，因为这些序列不是平稳序列，因此不满足使用该模型所需的假设。因此，我们使用一阶差分序列Δy_t 和 Δx_t ，因为它们是平稳序列。

5.1.2 结果与推断

为简便起见，我们将滞后阶数设为 $p = 10$，但我们检验了 p的多个取值，定性结果保持不变。该原假设检验的F统计量为 $F(10, 4252) = 1096$，其p值远低于0.001。这意味着我们有足够充分的证据得出结论：科技指数（序列 y_t）可以作为非科技指数（序列 x_t）的领先指标。

解读我们的结果时应当谨慎。我们的意思是， y_t 可以作为领先x_t的指标；也就是说，我们可以根据今天（以及此前若干时期） y_t 的情况，判断未来 x_t 会发生什么。然而，不能据此断言这种关系具有因果性。正如人们常说的，相关性并不意味着因果关系，因此不能将这些结果解读为 y_t 导致了未来的 x_t。成为领先指标的条件要宽松得多，即使不存在因果关系，也可以成立。我们还检验了是否存在反向关系，即 x_t 是否可以成为 y_t的领先变量，并发现确实存在反向关系。因此，在这种情况下，要确立因果关系将是一项非常艰巨的挑战。

5.2 结果的外部有效性

5.2.1 问题

有人可能会问，我们的分析是否适用于整个经济。这个问题主要源于我们只考察了纳斯达克100指数中的少数几家公司。该指数总共只有100家公司，其中的科技行业指数和非科技行业指数均由这100家公司构成。问题在于，科技行业可能还有其他未纳入纳斯达克100指数的公司。同样，纳斯达克100指数之外也可能存在其他非科技公司。这些公司的情况并未反映在我们的科技与非科技指数中。因此，从某种意义上说，本文得出的结论未必适用于整个科技行业，而可能只适用于纳斯达克100指数成分股；即便如此，这些公司至多也只是整个经济的一部分。

我们考察了长达十七年的时期，基本涵盖了纳斯达克100科技指数板块的整个生命周期。因此，从时间跨度来看，我们的结果基本覆盖了整个总体。

5.2.2 我们的回应

关于企业经济学的一篇有影响力的论文 Gabaix（2011年）指出，企业规模分布遵循一种被称为幂律分布的规律。这种分布表明，估值极高的公司非常少，而估值较低的公司数量极其庞大。其结果是，经济中的广泛波动可以由大型公司的波动来解释。Gabaix（2011年）表明：“美国规模最大的100家公司的特异性变动似乎能够

解释产出增长变动的约三分之一。”由于纳斯达克100指数包含规模最大的100家公司，因此，我们可以说，我们的发现对于整个经济也具有较强的适用性。其基本逻辑是，某一特定行业相当大一部分价值由头部公司贡献。另一种做法是纳入更多公司。可以考虑罗素2000[1] 指数中的公司，以观察在小盘股层面是否存在差异。然而，纳入更多公司也会带来特异性噪声，因此，增加公司数量未必总是一个好主意。

鉴于 Gabaix（2011）的研究结果，我们坚持使用纳斯达克100指数，并有信心认为我们的结果适用于整个经济。

6 结论

在本项目中，我研究了过去十七年科技与非科技行业之间的共同变动。我将这种密切的共同变动称为“耦合”。与之相反的现象自然是脱钩。我展示了，2015年之后，科技与非科技行业在水平值和波动率方面出现了脱钩。此外，我还检验了科技行业是否领先于其他行业，

我从中学到了几条经验。这次时间序列分析对我而言是一次很好的学习经历。我意识到，在着手建立主要模型之前，需要进行大量预处理。我一开始就说明，本次练习的目标是检验脱钩现象。为此，我们需要进行大量预处理。开始分析后，有时结果会指引你开展下一步工作。至少在一定程度上，我的情况确实如此。将两个序列绘制在一起后，我发现2015年之后出现了有趣的脱钩现象，并且在2019年进一步扩大。这一结果促使我考虑日后将本项目拓展为一篇完整的研究论文，进一步研究波动率变化。此次探索性数据分析（EDA）的要点可以简要概括为两句话：第一，科技指数序列（y_t）遵循 ARIMA(3,1,3) 模型。另一方面，非科技指数遵循 ARIMA(2,1,4) 模型。I=1 阶意味着两个序列都是非平稳的，但经过一阶差分后便会变为平稳序列。第二，我们有充分证据认为，科技指数可以视为经济其他部门的领先指标。

在我们的主要分析中，我们得出结论：在大部分时期，科技与非科技行业紧密耦合。对均值水平差异进行统计检验后，我们无法拒绝“两条序列在全样本中彼此接近”这一原假设。但如果将样本分为几个阶段，就能看到这两个行业出现了脱钩。新冠疫情前的2015年—2020年，是科技与非科技开始显现脱钩的时期。新冠肺炎和全球金融危机似乎都没有对科技与非科技序列的紧密共同变动产生足够大的影响。此外，就波动率而言，2015年之后，科技行业指数的波动率显著高于经济其他部门。我们将此称为科技行业与经济其他部门之间的波动率脱钩。我们所说的科技脱钩并非源于新冠疫情效应。不过，我们注意到，新冠肺炎加剧了这种脱钩。我们还注意到，新冠疫情后的时期通过非科技行业波动率上升，缩小了波动率差距。总体而言，2015年之后的时期以波动率上升为特征，尤其是科技行业推动了这一趋势。随后，非科技行业也加入了这一趋势。

总的来说，我们并不声称这些结果具有因果性。不过，鉴于其涵盖的年份和企业数量，这些结果为美国经济提供了重要见解。我很高兴能找到若干可供进一步研究的思路，以便提出因果性结论。

参考资料

Gabaix, X.（2011年），《总量波动的颗粒起源》，《计量经济学》**79**（3），733–772。Hamilton, J. D.（2020年），时间序列分析，普林斯顿大学出版社。https://books.google.com/books?hl=en&lr=&id=BeryDwAAQBAJ&oi=fnd&pg=PP1&ots=BgDX74aTjq&sig=pldAzsk9lBLHvBH-EWXwAZ8wmrI#v=onepage&q&f=false。Harvey, A.（2020年），《流行病时间序列模型：领先指标、对照组与政策评估》，*NIESR* 英国讨论论文（517）。https://www.niesr.ac.uk/publications/time-series-models-epidemics-leading-indicators-control-groups-and-policy-assessment?type=discussion-papers。

[1]罗素2000指数是一项追踪美国约2,000家小型市值公司表现的股票市场指数。

Hastie, T., Tibshirani, R. 和 Friedman, J. H.（2009年），《统计学习要素：数据挖掘、推断与预测》，第2卷，施普林格，纽约。Jacobsen, K. H. 和 Jacobsen, G. D.（2020年），‘美国各州新冠肺炎居家令与人口流动’，《世界医学与卫生政策》**12**(4), 347–356. PMID: 32837774; PMCID: PMC7405141. Poon, S.-H. 和 Granger, C. W.（2003年），‘金融市场波动率预测：综述’，《经济文献杂志》**41**(2), 478–539. Romer, P. M.（1994年），‘内生增长的起源’，《经济学展望杂志》**8**(1), 3–22.Gabaix (2011年) Poon 和 Granger (2003年) Hamilton (2020年) Harvey (2020年) Hastie, Tibshirani 和 Friedman(2009年)Jacobsen 和 Jacobsen(2020年) Romer(1994年)