

Data Science & AI for Economists

Lecture 12: Text Analysis(II)

Zhaopeng Qu

Business School, Nanjing University

December 11 2025



Roadmap

Today's Agenda

Part I: Basic Concepts

- What is Text Analysis?
- Why Text Analysis for Economists?
- Applications in Economics
- Basic Terminology
- Text Preprocessing
- Chinese Text Analysis Challenges
- Bag of Words & DTM
- TF-IDF

Part II: Advanced Topics

- Sentiment Analysis
- Topic Modeling (LDA)
- Text Classification
- Word Embeddings
- Information Extraction

Text Similarity and Semantic Analysis

Part I: Four Paradigms of Text Vectorization

Why Convert Text to Numbers?

Core Question

How to transform text into numbers for computers to understand?

Four Paradigms of Method Evolution

范式一	范式二	范式三	范式四	
统计表示	静态嵌入	动态嵌入	生成式LLM	
(1990s)	(2013)	(2018)	(2022)	
TF-IDF	Word2Vec	BERT	GPT-4/Claude	
词频统计	语义学习	上下文理解	直接完成任务	

Paradigm 1: Statistical Representation

Core Idea: Count Word Frequencies

Bag of Words (BoW) Model

将文档视为词的"袋子", 忽略词序, 只统计出现次数

Example:

- Doc1: "央行提高利率抑制通胀"
- Doc2: "通胀压力促使央行加息"

文档	央行	提高	利率	抑制	通胀	压力	促使	加息
Doc1	1	1	1	1	1	0	0	0
Doc2	1	0	0	0	1	1	1	1

Paradigm 1: Statistical Representation

TF-IDF: Highlight Important Words

- 假设文档总数为1000篇，平均每篇文档总词数为5000个
- $TF = \text{词在文档中的出现次数} / \text{文档总词数}(5000)$
- $IDF = \log(\text{总文档数}1000 / \text{包含该词的文档数})$
- $TF-IDF = TF \times IDF$

词	出现文档数(共1000篇)	在单篇文档中出现次数	TF(词频)	IDF(逆文档频率)	TF-IDF	含义
的	1000	500	$500 / 5000 = 0.10$	$\log(1000 / 1000) = 0.00$	$0.10 \times 0.00 = 0.000$	无信息量
经济	800	250	$250 / 5000 = 0.05$	$\log(1000 / 800) = 0.22$	$0.05 \times 0.22 = 0.011$	太常见
量化宽松	15	100	$100 / 5000 = 0.02$	$\log(1000 / 15) = 1.82$	$0.02 \times 1.82 = 0.036$	高区分度

Paradigm 1: Statistical Representation

Disadvantages

- 忽略词序: "狗咬人"="人咬狗"
- 同义词无法区分: "汽车"≠"轿车"
- 高维稀疏 (维度=词汇量): TF-IDF矩阵通常非常稀疏
- 无法处理一词多义: TF-IDF无法区分一词多义

Advantages

- 简单直观: 易于理解
- 计算快速: 计算速度快
- 可解释性强: 易于解释

Applications

- 经济学期刊的主流方法: 可用于文本分类、文本聚类、文本相似度计算等。

Paradigm 2: Static Word Embeddings (Word2Vec)

Core Idea: Distributional Hypothesis

"一个词的含义由它的上下文决定" — J.R. Firth, 1957

- 所以我们可以让经常出现在**相似上下文中的词**，**拥有相似的向量**，这就是Word2Vec的核心思想。

Example

"The Fed raised interest rates..."

"The central bank increased borrowing costs..."

- 下列词组可能会拥有**相似的向量**:
 - "The Fed"和"The central bank"
 - "raised"和"increased"
 - "interest rates"和"borrowing costs"

Paradigm 2: Static Word Embeddings (Word2Vec)

- Then the vectors of "The Fed" and "The central bank" are:

"The Fed" \rightarrow [0.12, -0.45, 0.78, 0.33, -0.21, ..., 0.56] (300个连续值)

"The central bank" \rightarrow [0.15, -0.41, 0.82, 0.29, -0.18, ..., 0.51] (300个连续值)

- 向量的维度通常为50-500维，通常远小于词汇量，最常用的维度为300维。
- Question: How to get the actual values of vectors?
- Answer: Use ML algorithms normally Neural Network to get the values of vectors.
- CBOW（连续词袋）：用周围词预测中心词
- Skip-gram：用中心词预测周围词

输入: ["The", "central", "_", "raised",
"rates"]

目标: 预测 "bank"

输入: "bank"

目标: 预测 ["The", "central", "raised",
"rates"]

Paradigm 2: Static Word Embeddings (Word2Vec)

Pre-trained Chinese Resources

资源	语言	说明
Google News	英文	300万词，Word2Vec经典模型
腾讯AI Lab	中文	800万词，推荐
哈工大HIT词向量	中文	哈工大贡献的中文词向量
百度百科词向量	中文	基于百科大规模训练

- 核心思想：无需从零训练，直接加载已训练好的词向量。

Paradigm 3: Contextual Dynamic Embeddings

Limitations of Word2Vec

- In Word2Vec,

"bank" \rightarrow [0.12, -0.45, 0.78, ...] \leftarrow 永远是这个向量

- In reality,

"I deposited money in the bank" \rightarrow bank = 银行

"I sat on the river bank" \rightarrow bank = 河岸

"You can bank on me" \rightarrow bank = 依靠

Paradigm 3: Contextual Dynamic Embeddings

BERT's Breakthrough:

- 情景动态嵌入: Same Word, Different Context = Different Vector
- 核心机制: Transformer的自注意力机制(Self-Attention Mechanism)
 - BERT在生成某个词的向量时, 会同时"看"整个句子, 让每个词根据上下文调整自己的表示

"The central bank raised interest rates"

- When processing "bank", BERT will ask:
 - "central" is nearby → "central" might be the central bank
 - "raised" is after → the action is "raising"
 - "rates" is after → it involves interest rates
- Comprehensive judgment: "central" means "central bank"
- Then generate the vector of "bank" by the context of the sentence.

Paradigm 4: Generative Large Language Models

Paradigm Shift: From "Training Models" to "Writing Prompts"

传统流程（BERT时代）	LLM流程
收集数据	设计Prompt
人工标注	API调用
训练模型	获取结果
预测	
需要：编程、GPU、标注数据、数周	需要：清晰描述、几分钟

- LLM让文本分析重新民主化：不需要深度学习专业知识，不需要编程，不需要GPU，不需要标注数据，不需要数周，只需要清晰描述任务，即可完成分类。

Core Capabilities of LLM Text Analysis

1. Zero-shot Classification

任务：判断央行声明是鸽派还是鹰派

- 传统方法：需要数千条人工标注的训练数据
- LLM方法：直接描述任务，即可完成分类

2. Complex Information Extraction

任务：从年报中提取风险因素、管理层态度、关键指标

- 传统方法：设计复杂的正则表达式和NER模型
- LLM方法：用自然语言描述需要提取的信息

3. Fine-grained Sentiment Analysis

- 识别讽刺、反语
- 理解隐含立场
- 区分事实 vs 观点

4. Topic Classification

- 自动发现文档的潜在主题
- 无需预定义主题
- 可解释性强

Paradigm 4: Generative Large Language Models

LLM vs Traditional Methods

任务	传统方法	LLM方法	优势
情感分析	训练分类器	Zero-shot prompt	无需标注
主题分类	LDA	直接分类+解释	可解释性强
信息抽取	正则+NER	结构化输出	灵活准确
文本标注	众包平台	API批量处理	成本低、一致性高
翻译/摘要	专业服务	API调用	即时、便宜

Embedding Word and Sentence Method Selection

- Question: Which method should I use to embed words and sentences?
- Answer: It depends on your task.
- Simple Word Frequency / Keyword Statistics → TF-IDF (Simple, Explainable)
- Measure Document Similarity / Clustering → Word2Vec + Average
- Classification / Sentiment Analysis → BERT Fine-tuning / LLM
- Complex Information Extraction / Reasoning → LLM

Applications of Text Analysis

Applications Overview

Core Applications of Text Analysis

应用	核心问题	是否需要标注	输出
文本相似度	这些文档有多相似?	不需要	相似度分数
文本分类	这篇文档属于哪个类别?	需要	预定义类别
文本聚类	这些文档可以分成几组?	不需要	自动发现的组
情感分析	这段文字表达什么情感/态度?	通常需要	情感标签/分数
主题模型	这些文档在讨论什么话题?	不需要	潜在主题分布

Relationships

- 直接计算: 文本相似度
- 有监督的学习: 文本分类、情感分析
- 无监督的学习: 文本聚类、主题模型

Integration with Four Paradigms

每种应用都可以使用不同范式的文本表示方法:

- 传统方法: TF-IDF + 机器学习分类器
- 嵌入方法: Word2Vec/BERT + 深度学习
- LLM方法: 直接用Prompt完成任务

Similarity Measurement Methods

1. Cosine Similarity (余弦相似度)

$$\text{CosSim}(\vec{A}, \vec{B}) = \frac{\vec{A} \cdot \vec{B}}{\|\vec{A}\| \times \|\vec{B}\|}$$

- $\vec{A} \cdot \vec{B}$, 即向量A和向量B的点积
- $\|\vec{A}\| \times \|\vec{B}\|$, 即向量A和向量B的模长的乘积

几何直觉: 测量两个向量的夹角

- 1 = 方向相同 → 非常相似
- 0 = 垂直 → 不相关
- 优点: 对文档长度不敏感

bank 和 finance 的向量表示

bank $\rightarrow [0.12, -0.45, 0.78, 0.33, -0.21, \dots, 0.56]$

finance $\rightarrow [0.15, -0.41, 0.82, 0.29, -0.18, \dots, 0.51]$

$$\text{Cosine Similarity} = \frac{\text{bank} \cdot \text{finance}}{\|\text{bank}\| \times \|\text{finance}\|} = 0.92 \quad \leftarrow \text{非常相似}$$

Similarity Measurement Methods

2. Jaccard Similarity

$$\text{Jaccard}(A, B) = \frac{|A \cap B|}{|A \cup B|}$$

集合直觉：两个文档共享了多少词汇？

Doc1词集: {经济, 增长, 技术, 创新} Doc2词集: {经济, 技术, 创新, 发展}

交集: {经济, 技术, 创新} = 3

并集: {经济, 增长, 技术, 创新, 发展} = 5

- the Jaccard Similarity is $\frac{3}{5} = 0.6$

Similarity Measurement Methods

3. Method Selection

场景	推荐方法
比较语义内容	余弦相似度 + 嵌入向量
检测词汇重叠/抄袭	Jaccard相似度
考虑词频权重	余弦相似度 + TF-IDF

- 经济学研究中，我们更关注语义内容，因此推荐使用余弦相似度 + 嵌入向量。

Applications: Measuring Technological Innovation

Kelly et al. (2021, AER: Insights): Patent Text and Innovation

研究问题：如何客观测量一项专利的创新程度？

方法：

1. 将每项专利表示为TF-IDF向量
2. 计算新专利与过去5年所有专利的余弦相似度
3. 创新度 = $1 - \max(\text{相似度})$

核心指标：

- Backward Similarity：与过去专利的最大相似度
| 低 = 更具突破性 |
- Forward Similarity：被未来专利引用时的相似度
| 高 = 更有影响力 |

发现：

- 能识别出真正的突破性创新
- 与传统引用指标互补
- 可追溯200年技术史

Text Classification

Definition

将文档自动归入预先定义类别中

Typical Applications

研究场景	分类任务	类别示例
央行沟通	政策立场分类	鸽派 / 中性 / 鹰派
企业年报	风险披露分类	财务风险 / 运营风险 / 法律风险
新闻分析	经济新闻分类	宏观 / 行业 / 公司 / 政策
政治文本	意识形态分类	左 / 中 / 右

Method Selection

Task	Method	Characteristics
传统	TF-IDF + SVM / 朴素贝叶斯	简单、可解释、需要特征工程
深度学习	Word2Vec + CNN / LSTM	自动学习特征、需要大量数据
预训练	BERT微调	效果最好、需要GPU
LLM	Zero-shot / Few-shot Prompt	无需训练、灵活、成本高

Application: Media Bias Measurement

Gentzkow & Shapiro (2010, Econometrica)

问题：如何客观测量媒体的政治倾向？

方法：

1. 收集国会议员演讲，标注其党派（民主党/共和党）
2. 识别各党派的"标志性短语"
3. 用这些短语对媒体报道进行分类
4. 计算媒体的"政治倾斜指数"

发现：媒体偏见与受众偏好高度相关（迎合读者）

对同一件事情，不同党派的用语不同：

民主党倾向用语	共和党倾向用语
estate tax (遗产税)	death tax (死亡税)
undocumented workers	illegal aliens
war in Iraq	war on terror

Text Clustering

Definition

将文档自动分成若干事先未知的组，使组内文档相似、组间文档不同

Classification vs Clustering

维度	文本分类	文本聚类
类别	预先定义	算法发现
标注数据	需要	不需要
学习方式	监督学习	无监督学习
适用场景	类别已知且稳定	探索性分析

Common Methods

方法	原理	优缺点
K-Means	最小化组内距离	简单快速，需指定K
层次聚类	自底向上合并	可视化好，计算慢
谱聚类	基于图论	效果好，计算复杂

Application: Clustering Analyst Report

Analyst Report Clustering

问题：不同分析师的研究风格有何差异？

方法：

1. 收集某行业所有分析师报告
2. 用Sentence-BERT编码每份报告
3. 聚类发现不同的"报告类型"

可能发现的簇：

簇	特征	代表词
簇1	基本面分析	营收、利润率、增长
簇2	技术分析	支撑位、压力位、趋势
簇3	行业展望	政策、竞争格局、行业趋势
簇4	事件驱动	并购、管理层变动、诉讼

Sentiment Analysis

Definition

自动识别文本中表达的情感、态度或观点

Task Types

类型	输出	示例
极性分类	正面 / 中性 / 负面	产品评论
情感强度	连续分数(-1到+1)	情感程度
细粒度情感	具体情感类型	愤怒 / 恐惧 / 喜悦 /
立场检测	支持 / 反对 / 中立	对议题的态度

方法演进

方法	原理	适用场景
词典方法	统计正负面词数量	简单任务、需要可解释性
机器学习	训练分类器	有标注数据时
深度学习	BERT等预训练模型	追求最高精度
LLM	Zero-shot分析	无标注、复杂情感

Sentiment Analysis Cases

Case 1: Tetlock (2007, JF) - Media Pessimism and Stock Market

问题：媒体情绪能预测股市吗？

方法：

- 1. 收集《华尔街日报》"Abreast of the Market"专栏
- 2. 使用Harvard-IV词典计算悲观情绪指数
- 3. 检验与次日股市收益的关系

Harvard-IV词典示例：

负面词	正面词
loss, decline, risk	gain, growth, profit
concern, fear, weak	strong, improve, success

发现：

- 高悲观情绪 → 次日市场下跌压力
- 异常高/低情绪 → 随后反转
- 媒体情绪包含噪音交易者信息

Challenges in Sentiment Analysis

Core Challenges

挑战	示例	难点
反语/讽刺	"这个政策真是太'棒'了"	字面与实际意思相反
隐含情感	"该公司连续三年亏损"	无明确情感词但含负面信息
条件句	"如果经济衰退，利润将下降"	假设性陈述
否定	"不会出现大幅下跌"	双重否定
比较	"比竞争对手更差"	需要理解比较对象

Advantages of LLM in Sentiment Analysis

传统方法的困境: "虽然一季度业绩不及预期，但管理层对全年展望保持乐观"

- 词典方法: 检测到"不及预期"(负面) + "乐观"(正面) → 混淆
- LLM方法: 理解整句语义 → 判断为"谨慎乐观"

Deepening Topic Model Applications

Topic Models vs Other Methods

维度	主题模型	文本分类	聚类
类别/主题	自动发现	预定义	自动发现
文档归属	可属于多主题	只属于一个类	只属于一个簇
输出	概率分布	类别标签	簇标签
可解释性	高（主题词）	取决于方法	需人工解读

Deepening Topic Model Applications

Unique Value of Topic Models in Economics

1. 发现未知结构

- 不需要预设研究假设
- 让数据"说话"

2. 时间序列分析

- 追踪主题随时间的变化
- 构建"注意力指数"

3. 降维与特征工程

- 将高维文本压缩为低维主题向量
- 作为回归分析的控制变量

Extended Topic Model Cases

Case 1: Hanley & Hoberg (2010, RFS) - IPO Information Content

问题：IPO招股书的信息含量如何影响定价？

方法：

1. 对IPO招股书应用LDA提取主题
2. 计算每份招股书的"标准化程度"
3. 检验与IPO抑价的关系

发现：

- 主题分布越独特（信息越丰富）→ 抑价越低
- 标准化的"模板"语言 → 信息不对称更严重

Extended Topic Model Cases

Case 2: Mueller & Rauh (2018, QJE) - Linguistic Signals of Political Violence

问题：能否从领导人演讲预测政治暴力？

方法：

1. 收集多国领导人演讲文本
2. 用主题模型提取演讲主题
3. 构建"好战性"主题指标

发现：

- 特定主题强度上升 → 后续暴力冲突概率增加
- 文本信号具有预测价值

Combining Methods

Combining Methods

组合	应用示例
聚类 + 分类	先聚类发现类别，再训练分类器
主题 + 情感	分析每个主题的情感倾向
聚类 + 情感	识别不同情感群体
主题 + 分类	用主题分布作为分类特征

References

- Gentzkow, M., Kelly, B., & Taddy, M. (2019). Text as Data. *Journal of Economic Literature*
- Ash, E., & Hansen, S. (2023). Text Algorithms in Economics. *Annual Review of Economics*