

# 複雜系統在語言科技中的應用

## （生成語法與形式語意學的整合視角）

# 學習目標

- 第一部分：複雜系統基礎理論
- 第二部分：生成語法的複雜系統觀點
- 第三部分：形式語意學與複雜性
- 第四部分：語言科技的應用
- 第五部分：批判性反思
- 第六部分：未來展望與結論

# 第一部分：複雜系統基礎理論

# 什麼是複雜系統？

- **簡單定義：**由大量相互作用的組件構成的系統
- **複雜定義：**從「遊戲理論」的「觀察者亦為受觀察物」到「混沌理論」的「看似隨機的表現其實由簡單規則累積而成」最終到「複雜系統」的「湧現、自組織、非線性」。
- **關鍵概念：**系統的整體行為無法僅由個別組件預測

# 複雜系統的核心特徵

- 多尺度組織 (Multi-scale organization)：從微觀到宏觀的層次結構
- 路徑依賴 (Path dependency)：歷史影響現在、前項影響後項、下層影響上層
- 涌現 (Emergence)：整體大於部分之和
- 自適應性 (Self-Adaptivity)：系統隨環境變化而演化
- 非線性互動 (Nonlinear interactions)：小變化可能導致大影響

# 複雜系統的數學工具

- 網路理論 (Network Theory)：
  - 描述節點與連接的關係，即「圖論、集合與樹」
- 動態系統理論 (Dynamical Systems)：
  - 研究系統隨時間的演化，即「 $\Delta T$  必然為系統的因子之一」
- 資訊理論 (Information Theory)：
  - 量化系統的複雜度與熵，即「info vs. data」或「signal vs. noise」
- 計算理論 (Computation Theory)：
  - 分析系統的計算能力，即「什麼是能算的，什麼是不能算的？」

# 為何語言是複雜系統？

- 多層次結構：音韻、詞彙、句法、語意、語用
- 涌現性質：語意不僅是詞彙的簡單組合
- 社會互動：語言透過使用者互動而演化
- 適應性：語言持續適應溝通需求
- 歷史演化：語言變遷展現路徑依賴性

# 語言複雜性的層次

- 微觀層次：音素、語素的組合規則
- 中觀層次：詞組結構、句法樹、語意合成
- 宏觀層次：語篇結構、對話系統、語言變遷
- 跨層互動：各層次之間的雙向影響
- 認知基礎：語言處理的神經機制

# 複雜系統觀點的優勢

- 整合視角：連結不同語言學子領域
- 動態建模：捕捉語言的時間演化
- 預測能力：理解語言變遷與習得
- 跨學科對話：與認知科學、計算機科學整合
- 實用價值：改進語言科技應用

# 語言系統的自組織性：語言不是約定俗成的

- 詞彙網絡的無尺度特性 (scale-free)
- 語法規則的自發湧現：
  - 語法規則是在觀察中發生的，還是它本體（自適應）發生的？
- 語言習得中的模式形成：
  - 雙語環境的幼童自主把 ありがとうございます 說成 ありがとう many thanks
- 社會語言變異的動態平衡
- 語言接觸中的結構轉移

# 複雜性度量

- Kolmogorov 複雜度：
  - 描述語言模式的複雜度。複雜度愈高，愈不可能是語言 / 訊號。
- 熵與資訊率：量化語言的不確定性
- 網路複雜度：詞彙與句法網路的拓撲性質
- 層次深度：句法樹與語意組合的遞迴層次
- 計算複雜度：語言處理所需的計算資源 (e.g.,  $O(n)$ )

# 第一部分小結

- 複雜系統提供理解語言的新框架
- 語言展現典型的複雜系統特徵
- 需要多尺度、動態的分析方法
- 數學工具有助於精確建模
- 為後續討論奠定理論基礎

# **第二部分：生成語法**

**( 作為複雜系統的句法理論 )**

# 生成語法基本概念

- Chomsky 的語言能力 (competence) 理論
- 普遍語法 (Universal Grammar, UG)
- 參數理論 (Parametric variation)
- 遞迴性 (Recursion) 與無限生成
- 內在語言 (I-language) vs. 外在語言 (E-language)

# 最簡方案 (Minimalist Program)

- 核心操作：Merge（融接） 、 Move（移位）
- 介面條件：PF（語音形式）與 LF（邏輯形式）
- 經濟原則：最小化計算負擔
- 特徵檢驗（Feature checking）
- 階段理論（Phase theory）

# 生成語法的複雜系統性質

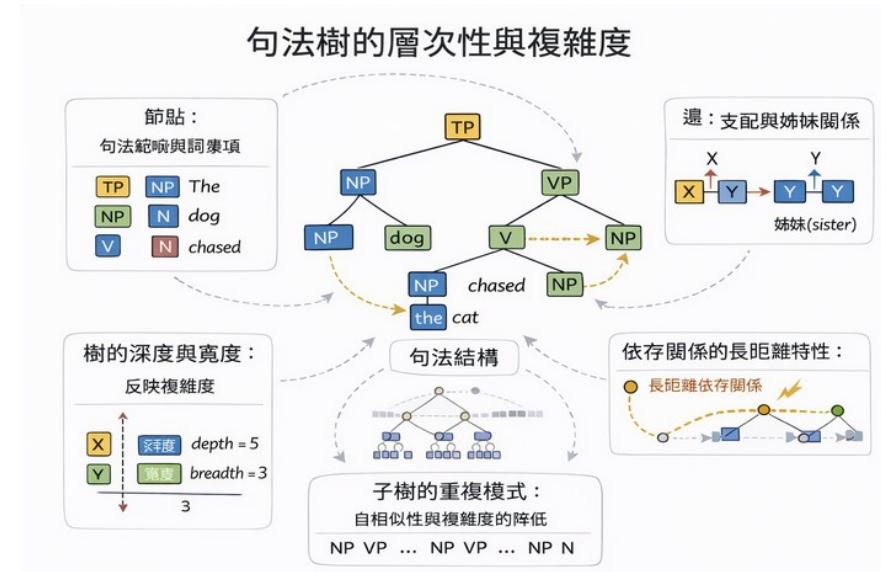
- 遞迴合併產生離散無限性
- 少數原則生成豐富結構（湧現）
- 參數設定的級聯效應（非線性）
- 句法樹的階層組織（多尺度）
- 跨語言變異的系統性模式

# Merge 操作的複雜性

- 二元合併：最簡單的結構建構（為什麼 2 最簡單？）
- 遞迴應用：產生任意複雜的結構
- 標籤演算 (Labeling algorithm)
- 內部 Merge (Internal Merge) : 產生位移
- 計算複雜度：context-free 到 mildly context-sensitive

# 句法樹作為網路結構

- **節點：句法範疇與詞彙項**
  - **邊：支配與姊妹關係**
  - **樹的深度與寬度：反映複雜度**
  - **子樹的重複模式：自相似性與複雜度的降低**
  - **依存關係的長距離特性**



# 參數理論與複雜性

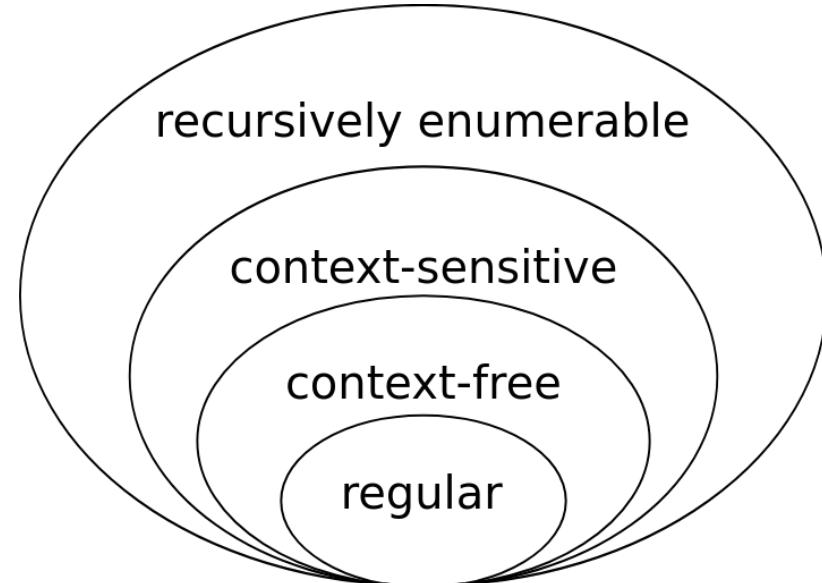
- 參數：語言變異的開關
- 參數空間：可能語法的組合爆炸
- 參數設定的觸發：語言習得
- 參數級聯：一個參數影響多個現象
- 宏參數 vs. 微參數的辯論

# 移位與依存關係

- wh- 移位、主題化、焦點移位
- 長距離依存的複雜度
- 島嶼限制 (Island constraints)
- 痕跡理論與複本理論 (Copy theory)
- 移位的認知成本

# 生成語法的計算模型

- 形式文法層級：Chomsky hierarchy
- 自然語言的溫和語境敏感性 (mild-context sensitivity)
- Minimalist Grammars (MG) 的形式化
- 可分析性與可學習性



# 句法處理的神經基礎

- Broca 區與句法處理
- 遷迴結構的神經實現
- 左半球優勢與句法網絡
- 句法與工作記憶的關係

# 跨語言的句法變異

- 詞序參數：SVO, SOV, VSO 等
- Pro-drop 參數
- wh- 移位 vs. wh-in-situ
- 名詞組的結構變異
- 變異背後的普遍原則

# 生成語法與語言科技

- 句法分析器 (Parsers) 的理論基礎
- 樹庫 (Treebanks) 的構建 (obsolete...maybe?)
- 機器翻譯中的句法轉換
- 語法錯誤檢測
- 神經網路能否學會句法？ (we know it can't now by 2024.)

# 第二部分小結

- 生成語法描述離散的結構系統
- 遞迴與參數產生複雜性
- 句法是多層次的組織
- 涌現性質來自簡單操作
- 為語言科技提供理論指導

# 第三部分：形式語意學

- 意義的非複雜系統觀：形式語意學的計算「並不是」複雜系統！
- 它是因果邏輯的計算過程。

# 形式語意學基礎

- 真值條件 (Truth conditions)
- 指稱 (Reference) 與謂述 (Predication)
- 組合性原則 (Compositionality) : Frege 原則
- 邏輯形式 (Logical Form, LF)
- 模型論語意學 (Model-theoretic semantics) :
  - 把前四者結合起來，也可以成為一個語意模型
  - 模型「並不是」只有機率模型一種

# Montague 語意學

- 類型論 (Type theory) : e (個體) 、 t (真值)
- $\lambda$ -演算 (Lambda calculus)
- 內涵邏輯 (Intensional logic)
- 可能世界語意學 (Possible worlds)
- 自然語言作為形式語言

# 語意組合的複雜性

- 函數應用 (Function application)
- 類型提升 (Type raising)
- 組合子邏輯 (Combinatory logic)
- 量化詞的範疇提升
- It's complicated, but it's not complex!

# 量化與範疇

- 廣義量詞理論 (Generalized quantifiers)
- 量化詞的單調性 (Monotonicity)
- 範疇的包含關係
- 多重量化的歧義
- 約束變項的語意解釋

# 事件語意學

- 事件結構與論元結構
- 體貌 (Aspect) 的形式化
- 因果關係的表徵

# 時態與模態

- 時間邏輯 (Temporal logic)
- 過去、現在、未來的表徵
- 模態算子：必然、可能
- 時態與模態的互動

# 認識模態 vs. 道義模態

- 認識模態 (Alethic Modality)
- 定義：描述事物真實性或可能性狀態的模態。
- 例子：
  - 「 $1+1=2$ 」是一個必然為真的命題。
  - 「我現在沒有吃飽」這個命題是偶然的，可能為真也可能不為真。
  - 「火星上有生命」是可能的命題，但尚未被證明是必然或偶然的。
  - 核心概念：必然性、偶然性、可能性。
- 道義模態 (Deontic Modality)
- 定義：描述行為是否被允許、禁止或是否為義務的模態。
- 例子：
  - 「你必須遵守交通規則」（義務）。
  - 「你不能在圖書館大聲喧嘩」（禁止）。
  - 「你可以選擇是否要參加派對」（允許）。
  - 核心概念：義務、許可、禁止。

# 指稱與回指

- 指示詞 (Indexicals) 的語意
- 定描述詞 (Definite descriptions) : Russell vs. Strawson
- 代詞的約束理論
- 動態語意學 (Dynamic semantics)
- 話語表徵理論 (DRT)

# 預設與蘊涵

- 語意預設 (Presupposition)
- 預設投射問題 (Projection problem)
- 蘊涵 (Entailment ; 必然性) 與推論 (Implication ; 可能性)
- 會話蘊涵 (Conversational implicature)
- Grice 的合作四原則

# 語意學的非複雜系統特徵

- 組合性：
  - 局部規則產生全局意義
  - 但全局即為「局部的總合」，沒有超過！
- 上下文依賴：語境影響解釋的方式可用同一套邏輯推算
- 多義性：一個表層形式多種底層意義可用同一套邏輯推算
- 推理網絡：意義之間的蘊涵與推論關係
- 語用與語意的介面

# 向量空間語意學？

- 詞向量 (Word embeddings) : Word2Vec, GloVe
- 分佈假說：相似上下文產生相似意義（嗎？）
- 向量的算術運算： $\text{king} - \text{man} + \text{woman} \approx \text{queen}$
- 高維空間的複雜結構
- 與形式語意學的整合

# 組合向量語意學

- 張量積與組合函數
- 遞迴神經網絡（RNN）的語意組合
- Tree-LSTM 與句法引導組合
- 注意力機制與語意對齊
- Transformer 的語意表徵

# 多義性與歧義消解

- 字典：
  - 詞彙多義：一詞多義 vs. 同形異義
- 句法：
  - 結構歧義：附加歧義、範疇歧義
- 語意：
  - 語用歧義：指稱歧義
- 語意 + 語用：
  - 上下文線索與消解策略
- 資料分佈：
  - 貝葉斯推論模型

# 第三部分小結

- 形式語意學提供精確的意義理論
- 組合性是語意複雜性的核心
- 語意網絡展現複雜的結構
- 上下文與推理增加複雜度
- 形式與分佈方法的互補
- 然而，它並不是複雜系統。Why?

# 第四部分：語言科技應用

複雜系統觀點的實踐

# 自然語言處理概覽

- 核心任務：分詞、詞性標註、句法分析、語意分析
- 傳統方法：基於規則、統計模型
- 深度學習革命：神經網絡方法
- 大型語言模型（LLM）的興起
- 評估標準與挑戰

# 句法分析技術

- 結構句法分析 (Constituency parsing)
- 依存句法分析 (Dependency parsing) (*deprecated now*)
- 神經句法分析器 (*never actually works...*)

# 語意角色標註 (效果不如預期的那些方法)

- PropBank 與 FrameNet
- 論元結構的自動識別
- 序列標註模型：條件隨機場 (Conditional Random Field, CRF), BiLSTM
- 預訓練模型的語意理解
- 跨語言語意角色標註

# 機器翻譯

- 統計機器翻譯 (SMT)：短語基礎
- 神經機器翻譯 (NMT)：Seq2Seq 模型
- 注意力機制的引入
- Transformer 架構：BERT, GPT
- 多語言模型與零樣本翻譯

# 問答系統

- 抽取式 vs. 生成式問答
- 知識庫問答 (KBQA)
- 閱讀理解：SQuAD, RACE
- 檢索增強生成 (RAG)
- 複雜推理與多跳問答

# 對話系統

- 任務導向 vs. 開放域對話
- 對話狀態追蹤
- 回應生成策略
- 對話管理的強化學習
- ChatGPT 與大型對話模型

# 語言生成

- **文本摘要：抽取式與生成式**
- **數據到文本生成**
- **故事生成與創意寫作**
- **可控生成：風格、情感、主題**
- **評估指標：BLEU, ROUGE, BERTScore**

# 大型語言模型 (LLM)

- GPT 系列：自回歸語言模型
- BERT 系列：掩碼語言模型
- 預訓練與微調範式
- 提示工程 (Prompt engineering)
- 觀察到的湧現能力：推理、規劃、工具使用

# 第四部分小結

- 語言科技整合複雜系統觀點
- 神經方法學習複雜語言模式
- 理論語言學提供指導與評估
- 挑戰來自語言的本質複雜性
- 但需要批判性反思 LLM 的性質

# 第五部分：批判性反思

## 兩種湧現的區分

- 弱湧現 (Weak Emergence)
  - 原則上可還原，但實務上困難
  - 是認識論的複雜性
  - 來自觀察者的描述視角
- 強湧現 (Strong Emergence)
  - 原則上不可還原
  - 新的因果力量
  - 是本體論的複雜性

### 區別 (Diff.)

認識論：牆上不可能有狗臉，只是因為某某原因，人類有此認知或詮釋  
本體論：牆上有一張狗臉

# LLM 真的是複雜系統嗎？

- 質疑的核心論點
- LLM 的”湧現”可能只是觀察者的描述：
  - 系統本身只做確定性矩陣運算
  - 每一步計算都是可預測的
  - “湧現能力”是我們無法追蹤細節（因實務上的困難）的結果
  - 不是系統固有的本體論特性

# 還原論視角

- LLM 的運作流程：
  - 輸入文本
    - Token 化
    - 嵌入向量
    - 多層 Transformer (矩陣乘法 + 激活函數)
    - 輸出概率分布
    - 生成文本
- 關鍵洞察：
  - 每一步都是確定性計算
  - 沒有真正的自主性或隨機性
  - 原則上完全可預測 (給定參數)

# Scaling Laws 的啟示

- 平滑的擴展律
- GPT 系列的能力可用平滑曲線預測
- 沒有明顯的”相變點”
- 所謂”湧現”可能是：
  - 人類主觀劃定的能力閾值
  - 漸進量變，而非質變
  - 測量粒度不足造成的錯覺
- 結論：LLM 的湧現可能是認識論的，非本體論的

# 與真實複雜系統的對比

- 特徵：**自然複雜系統** vs. **LLM**
- 自主性：**個體有自主行為** vs. **無自主性**
- 隨機性：**真實隨機過程** vs. **確定性計算**
- 開放性：**與環境持續互動** vs. **封閉的計算系統**
- 演化：**真實的適應與演化** vs. **參數固定（訓練後）**
- 因果力：**湧現層次有因果作用** vs. **只是底層計算的結果**

# 人類語言 vs. LLM

- 人類語言系統的獨特性
- 真正的複雜系統特徵：
  - 社會互動：多個自主主體的真實互動
  - 歷史演化：語言隨時間真實變遷
  - 認知基礎：神經生物學的隨機性與可塑性
  - 創造性：真正的新穎表達生成
- LLM 的局限：
  - 只是靜態參數的函數映射
  - 沒有真實的社會或認知基礎
  - "創造性" 只是訓練數據的重組

# 對語言學研究的啟示

- ⚠ 重要警告
- 不能直接用 LLM 推論人類語言能力：
- LLM 學到的”語法” ≠ 生成語法的心理現實
- LLM 的”語意理解” ≠ 人類的意義建構
- 統計相關性 ≠ 結構性語言知識
- 函數擬合 ≠ 語言能力 (competence)
- Chomsky 的批評是有道理的！

# 修正後的立場

- LLM 是什麼？
-  計算複雜的系統
  - 大量參數的非線性互動
  - 實務上難以完全理解
-  認識論意義的複雜性
  - 從觀察者角度展現複雜行為
  - 需要複雜系統工具分析
-  本體論意義的複雜系統
  - 沒有真正的湧現
  - 沒有自主性和適應性
  - 是確定性的計算裝置

# 正確的研究態度

- 對 LLM 的合理定位
- 應該做：
  - 研究 LLM 作為語言模式的統計模型
  - 分析其計算複雜性與表現
  - 用作探索語言現象的工具
  - 比較 LLM 與人類的行為差異
- 不應該做：
  - 認為 LLM 複製了人類語言能力
  - 用 LLM 的行為推翻語言學理論（你不會拿香蕉來證明芭樂不夠長，對吧？）
  - 忽視 LLM 與真實語言系統的本質差異

# 第五部分小結

- 湧現有弱 / 強之分：認識論 vs. 本體論
- LLM 的湧現是觀察者視角的產物
- LLM 是計算複雜而非本體論複雜系統
- 不能等同 LLM 與人類語言能力
- 需要批判性地應用複雜系統框架

# 第六部分：未來展望

複雜系統、語言學與科技的融合

# 語言科技的未來趨勢

- 更大規模的語言模型（仍需反思其本質）
- 多模態與具身智能
- 少樣本與零樣本學習
- 可解釋與可信賴的 AI
- 特定領域與低資源語言

# 複雜系統方法的深化

- 謹慎應用於不同對象
- 自然語言系統（真正的複雜系統）：
  - 動態網絡分析語言演化
  - 多主體模擬語言變遷
  - 跨尺度建模：從神經元到社會
- 人工語言模型（認識論複雜）：
  - 計算複雜度分析
  - 資訊論量化
  - 但不過度詮釋為本體論湧現

# 生成語法與神經網路

- 關鍵問題
  - 神經網絡能否實現生成語法？
  - 可能學到表面模式
  - 但不等於內化了生成語法規則
- 未來方向：
  - 結構歸納偏置 (Inductive biases)
  - 神經符號整合 (Neurosymbolic AI)
  - 可微分的句法結構
  - 明確整合語言學知識

# 跨學科研究機會

- 真正的整合
  - 語言學、計算機科學、認知科學
  - 複雜系統科學（謹慎應用）
  - 神經科學與腦影像研究
  - 社會科學與語言演化
  - 哲學：湧現、意識、意義的本質
- 關鍵：保持各學科的嚴謹性，不過度類比

# 開放問題（潛在的期中 / 末考題）

- 基本理論問題
  - 語言能力的本質是什麼？
  - 生成規則？統計模式？還是兩者皆有？
  - 組合性如何在神經網絡中實現？
  - 真的實現了嗎？還是只是近似？
  - 語言習得的關鍵機制？
  - 先天 UG？統計學習？社會互動？
  - 語言與思維的關係？
  - Sapir-Whorf 假說的現代版本

# 開放問題（續）

- 人工智能問題
  - 通用人工智能需要何種語言能力？
  - 統計模式夠嗎？還是需要結構知識？
  - LLM 的”理解”是什麼？
  - 真正的理解？還是複雜的模式匹配？
  - 如何整合符號與連結主義？
  - 神經符號 AI 的挑戰
  - 可解釋性與複雜性的權衡？
  - 越複雜越難解釋，但越有效

# 總結：複雜系統觀的核心洞察

- 對自然語言（真正的複雜系統）
  - 語言是多層次的複雜適應系統
  - 簡單規則透過遞迴產生無限複雜性
  - 社會互動產生真實的湧現性質
  - 理論需要複雜系統思維
- 對 LLM（認識論複雜）
  - 計算複雜但本質確定
  - 展現模式而非真正理解
  - 有用但不等於人類能力
  - 需謹慎詮釋