



生成 A I による S'_4 モジュラーフレーバーモデルの解析

西村 皇 (九州大学), 大塚 啓 (九州大学), 内山 晴貴 (九州大学)

arXiv:2503.21432 and arXiv:2504.00944





生成 A I による

S'_4 モジュラーフレーバーモデルの解析

西村 皇 (九州大学), 大塚 啓 (九州大学), 内山 晴貴 (九州大学)

arXiv:2503.21432 and arXiv:2504.00944



人工知能 (Artificial Intelligence)

- 言語の理解や推論、問題解決など所謂「知的行動」を人間に代わり、コンピューターに行わせる技術の総称。
- 特に、機械自身が学習する枠組みは「機械学習」と呼ばれる。




機械学習 (Machine Learning \subset AI)

- コンピュータが反復的にデータを学習する中で、
隠れたルールやパターンを抽出する技術の総称。

教師あり学習

教師なし学習



強化学習

S. Nishimura, C. Miyao, H. Otsuka,
• JHEP12(2023)021 (2304.14176 [hep-ph])
• 2409.10023 [hep-ph]

K. Ishiguro, S. Nishimura, H. Otsuka,
• JHEP08(2024)133 (2312.07181 [hep-th])

2025/09/01-05

PPP2025

拡散モデル (Diffusion Model : DM)


- 学習に基づいて、新しいデータや情報を生成できる
生成A I の一種。画像生成などに応用されている。

例) “Stable Diffusion” & “DALL-E in ChatGPT”

- 拡散過程 : データにノイズを付与する
生成過程 : ガウスノイズから適当なノイズを除去する

拡散モデル (DM)




- 拡散過程 : 完全なガウスノイズとなるまで、初期画像 G にノイズを加えていく。



拡散モデル (DM)

- 生成過程：ノイズ除去によって画像 G が生成されていく。

例) Make an image with a touch of Salvador Dalí.






2025/09/01-05

PPP2025

拡散モデル (DM)

- 条件付き拡散モデル：特定の条件ラベル L に従って画像を生成。

例) Make an image of “**The Persistence of Memory**” by Salvador Dalí,
with a touch of Van Gogh.

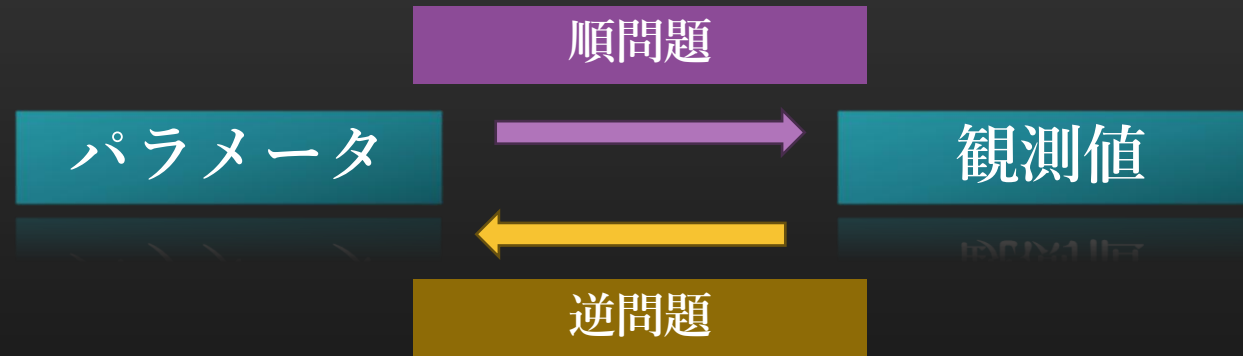


2025/09/01-05

PPP2025

要点

- 拡散モデルを、 S'_4 モジュラーフレーバー模型の分析に応用した。



- 逆問題的なアプローチによって様々なパラメータ解を発見し、 S'_4 模型が自発的な C P 対称性の破れを導きうることを示した。

標準模型



```
graph TD; A[標準模型] --> B[質量階層性]; A --> C[フレーバー混合の強弱]
```

質量階層性

フレーバー
混合の強弱

モジュラーフレーバー模型 (1)

- 標準模型の各場がモジュラー対称性に従うとし、
モジュラー対称性の表現からフレーバー物理に取り組む。
例) $SL(2, Z)$, $\Gamma_2 \simeq S_3$ (3 次の対称群), S'_4 (S_4 の二重被覆)
- 湯川結合もモジュラーフレーバー対称性の表現となり、
自由度として残っているパラメータ τ (モジュライ) の値次第で
質量固有値や混合行列が変化する。

モジュラーフレーバーモデル (2)

Y.Abe, T.Higaki, J.Kawamura, T.Kobayashi

- S'_4 モジュラーフレーバーモデルのSuperpotential

Phys.Lett.B 842 (2023) 137977

$$W = H_u \left\{ \sum_{a=1}^2 \alpha_a \left(QY_3^{(k_{ua}+k_Q)} \right)_1 u_a^c + \alpha_3 \left(QY_{\hat{3}}^{(k_{u3}+k_Q)} u_3^c \right)_1 \right\} \\ + H_d \sum_{i=1}^3 \left\{ \beta_i \left(QY_3^{(k_{di}+k_Q)} d_i^c \right)_1 \right\}$$

- モジュラー変換で $f_i(\gamma\tau) = (c\tau + d)^k \rho_{ij}(\gamma) f_j(\tau)$ と振る舞う特別な関数を、ウェイト k のモジュラー形式という。

Y_3^k がウェイト k の3表現。 α, β は適当な係数。

モジュラーフレーバーモデル (3)

- 表現とウェイトが決まると、湯川結合は
モジュラー形式を用いて以下のように計算される。

$$Y_u = \begin{pmatrix} \alpha_1 \left[Y_3^{k_{u1}+k_Q}(\tau) \right]_1 & \alpha_2 \left[Y_3^{k_{u2}+k_Q}(\tau) \right]_1 & \alpha_3 \left[Y_{\hat{3}}^{k_{u3}+k_Q}(\tau) \right]_1 \\ \alpha_1 \left[Y_3^{k_{u1}+k_Q}(\tau) \right]_3 & \alpha_2 \left[Y_3^{k_{u2}+k_Q}(\tau) \right]_3 & \alpha_3 \left[Y_{\hat{3}}^{k_{u3}+k_Q}(\tau) \right]_3 \\ \alpha_1 \left[Y_3^{k_{u1}+k_Q}(\tau) \right]_2 & \alpha_2 \left[Y_3^{k_{u2}+k_Q}(\tau) \right]_2 & \alpha_3 \left[Y_{\hat{3}}^{k_{u3}+k_Q}(\tau) \right]_2 \end{pmatrix}$$

モジュラーフレージャーモデル (4)

	Q	(u_1^c, u_2^c, u_3^c)	(u_1^c, u_2^c, u_3^c)	(H_u, H_d)
S'_4	3	$(1, 1, \hat{1}')$	$(1, 1, 1)$	$(1, 1)$
Weight	-4	$(0, -4, -3)$	$(0, -2, -4)$	$(0, 0)$

$$Y_u = \begin{pmatrix} \alpha_1 \left[Y_3^{k_{u1}+k_Q}(\tau) \right]_1 & \alpha_2 \left[Y_3^{k_{u2}+k_Q}(\tau) \right]_1 & \alpha_3 \left[Y_{\hat{3}}^{k_{u3}+k_Q}(\tau) \right]_1 \\ \alpha_1 \left[Y_3^{k_{u1}+k_Q}(\tau) \right]_3 & \alpha_2 \left[Y_3^{k_{u2}+k_Q}(\tau) \right]_3 & \alpha_3 \left[Y_{\hat{3}}^{k_{u3}+k_Q}(\tau) \right]_3 \\ \alpha_1 \left[Y_3^{k_{u1}+k_Q}(\tau) \right]_2 & \alpha_2 \left[Y_3^{k_{u2}+k_Q}(\tau) \right]_2 & \alpha_3 \left[Y_{\hat{3}}^{k_{u3}+k_Q}(\tau) \right]_2 \end{pmatrix}$$

- 実験値を再現するように、9個の定数 α, β やモジュライ τ の値を適切に決めなければならない。

モチベーション

- 拡散モデルは「生成 A I」¹として知られている。
(学習に基づいて、新しいデータや情報を生成できる)
- この性質を上手く活用することで、
 - 現実のフレーバー構造を再現する未知のパラメータを
観測値主導で生成 = 逆問題的アプローチ
 - 従来手法のように探索領域に制限を設けずとも、
広い範囲のパラメータから様々な候補を自動的に提案。

拡散過程の手順



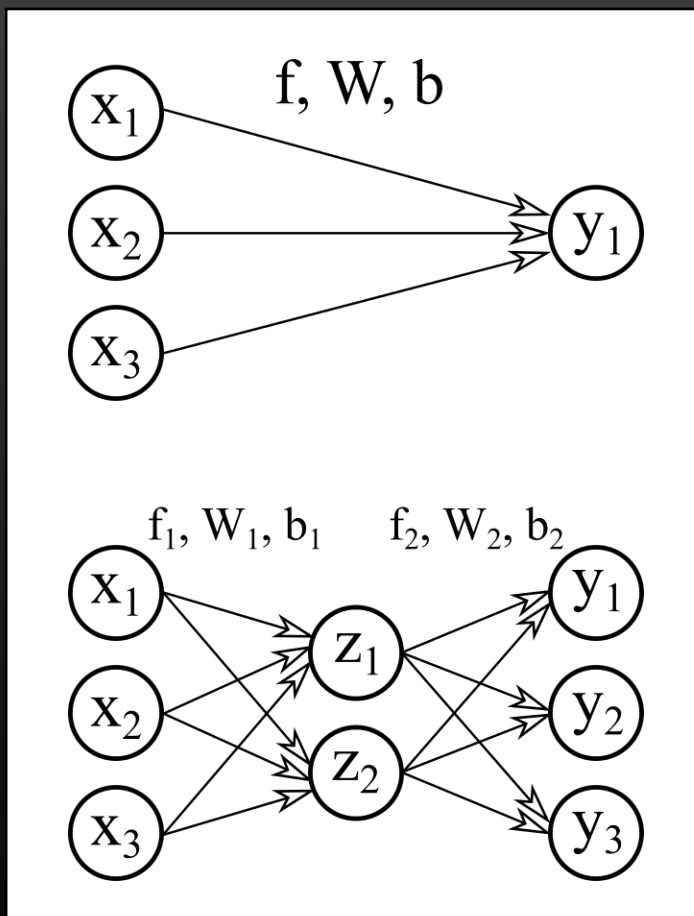
- 生成対象のフリーパラメータ $G = \{\tau, \alpha, \beta\}$ (α, β は実数)

G に対応する物理量ラベル
$$L = \left\{ \frac{m_u}{m_t}, \frac{m_c}{m_t}, \frac{m_d}{m_b}, \frac{m_s}{m_b}, |U_{ij}^{\text{CKM}}|, J^q \right\}$$

様々な時刻 $t \in \{1, 2, \dots, T\}$ に対して...

- 1) ランダムな初期データ G を準備し、対応する L を計算
- 2) ランダムな摂動 ΔG (ノイズ) を $G_t = \frac{T-t}{T}G + \frac{t}{T}\Delta G$ のように加算
- 3) G_t & L に基づいて ΔG を予測するようニューラルネットを訓練

ニューラルネットワーク (1)



- 生物の脳を模倣した数理モデル
典型的構成要素：入力層 (x) & 出力層 (y)

- 入力から出力が計算されていく

パラメータ W, b (ウェイト・バイアス)

活性化関数 f

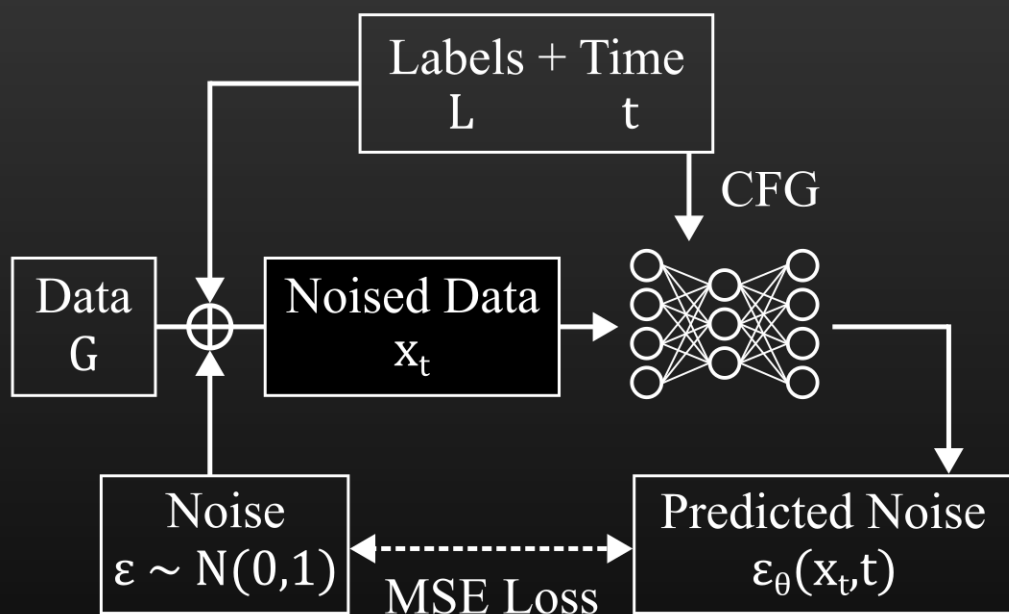
$$y_1 = f(W_1x_1 + W_2x_2 + W_3x_3 + b)$$

ニューラルネットワーク (3)

- 拡散モデルにおいては、


入力：ノイズデータ & ラベル情報

出力：予測ノイズ



- 重み W & バイアス b は、
予測ノイズと、実際の加算ノイズとの
差が小さくなるように更新されていく。
この更新作業が「学習」。

生成過程の手順



- 生成対象のパラメータ $G = \{\tau, \alpha, \beta\}$

実験に基づく物理量ラベル $L_{\text{exp}} = \left\{ \frac{m_u}{m_t}, \frac{m_c}{m_t}, \frac{m_d}{m_b}, \frac{m_s}{m_b}, |U_{ij}^{\text{CKM}}|, J^q \right\}$

- 1) ガウス分布に従う完全なノイズデータ G_T を用意
- 2) 予測ノイズ ΔG を $G_t = \frac{T-t}{T} G_{t+1} - \frac{t}{T} \Delta G$ と減算 (デノイズ)
- 3) 実際の観測値 L_{exp} に基づく新データ G_0 の生成が完了

計算資源

- 計算には Google Colaboratory でCPUのみ使用 (GPU不使用)
- 拡散過程には約 1 時間、
生成過程で 10^5 個のデータを生成するのも約4.6時間で完了。
- GPUで更なる高速化もできるが、
拡散モデルは省力的な計算環境でも活用可能。

生成過程の進捗 (1)

- 拡散モデルが導いたパラメータから 8 個の物理量を計算





$$\left\{ \frac{m_u}{m_t}, \frac{m_c}{m_t}, \frac{m_d}{m_b}, \frac{m_s}{m_b}, \theta_{12}^q, \theta_{23}^q, \theta_{13}^q, J^q \right\}$$

- 計算値と実験値 ($v_{\text{cal}}, v_{\text{exp}}$) を用いて χ^2 値を定義

$$\chi^2 = \sum \chi_i^2 = \sum \frac{(v_{i,\text{cal}} - v_{i,\text{exp}})^2}{v_{i,\text{error}}^2}$$




生成過程の進捗（2）

- 高精度に実験値を再現する解におけるモジュライ τ の分布。
生成データの増加に伴い、色々な候補が次々提案される。




生成過程の進捗 (3)

- 高精度に実験値を再現する解におけるモジュライ τ の分布。
生成データの増加に伴い、色々な候補が次々提案される。



結果：様々な解の生成（1）

- S'_4 模型のフレーバー構造は $\text{Im } \tau$ の値に鋭敏。僅かな値の違いが異なる構造を導くため、適切なパラメータ領域の推定自体が困難。解析的には、大きな $\text{Im } \tau$ で容易に再現可能（例： $\text{Im } \tau = 2.8$ ）
- 拡散モデルは探索するパラメータ領域に対して厳しい制限を必要とせず、色々な候補を生成する。比較的小さい $\text{Im } \tau \sim 2.2$ で妥当な解を発見できた。




結果：様々な解の生成（2）

- 拡散過程の実行時、学習データは広い定義域で準備される。

$$-\frac{1}{2} \leq \operatorname{Re} \tau \leq \frac{1}{2}, \quad \frac{\sqrt{3}}{2} \leq \operatorname{Im} \tau \leq 5$$

一方、生成A I は $\operatorname{Im} \tau \sim 2.2$ に集中する解を自動的に発見。

- 人間の経験だけからは見当が付きにくい領域でも、
拡散モデルは有望な解を探索し、提案してくれる。
(人間側で初期値や刻み幅を試行錯誤しなくてよい)




結果：自発的 C P 対称性の破れ

- 湯川結合内の係数 α, β が実数である中、 $\text{Re } \tau$ のみによって Jarlskog 不変量が再現された。＝「自発的 C P 対称性の破れ」

$$J_{\text{DM}} \sim 2.49 \times 10^{-5}, \quad J_{\text{exp}} = 2.87 \times 10^{-5}$$

- 先行研究：C P の破れを再現するためには
複素係数の導入が必要とされていた。
自発的 C P 対称性の破れの導出自体が興味深い。




総括：フレーバー物理への**拡散モデル**の応用

- S'_4 モジュラーフレーバー模型に着目し、
そのフリーパラメータを拡散モデルによって探索。
- 観測値主導の立場から、クォークセクターのフレーバー構造を
再現する様々なパラメータを、 $\text{Im } \tau$ が比較的小さい領域に発見。
「良い初期値」を探す手間がなく、探索範囲の厳しい制限も不要。
妥当な解の候補を機械が次々に提案してくれる。

総括：フレーバー物理への**拡散モデル**の応用

- 湯川結合に含まれる係数が実数であっても、 S'_4 模型で自発的 C P 対称性の破れを導くパラメータの候補を発見。



展望

- A_4 など異なるモジュラー対称性の下で、自発的 C P 対称性の破れは実現するか？一層非自明なパラメータは発見できるか？
- 既に得られている実験値を指定し、
所望のフレーバー模型の
予言を自動で導き出して
くれる枠組みへ。

