

# いつどこで何が起きるかを理解し、予測し、制御する

## ～点過程と機械学習を組み合わせたイベント時系列解析とその応用～

Understanding, Predicting, and Controlling Event Timing  
 - Event Time Series Analysis Using Point Processes and Machine Learning -



NTT コミュニケーション科学基礎研究所 協創情報研究部  
 知能創発環境研究グループ 特別研究員

### 金 秀明

Hideaki Kim

#### ●プロフィール

2007年東北大学理学部物理学科卒業。2013年京都大学大学院理学研究科博士課程修了。博士(理学)。同年、日本電信電話株式会社(現NTT株式会社)入社。2017年からNTTデータ在籍を経て、2019年より現職。機械学習、時系列解析の研究に従事。

ある出来事(イベント)の発生タイミングを事前に予測することができれば、事前対策によってリスクを軽減、あるいはその機会を最大限活用することができます。例えば、機器が故障する前に予防保全を実施する、顧客が来店する直前に割引クーポンを配布し購買を促進するなどが挙げられます。イベントに関するデータを解析し発生タイミングを予測する枠組みは「イベント時系列解析」と呼ばれます。本講演では、機械学習に基づくイベント時系列解析を通じて、イベントの発生メカニズムの特定と将来予測に関する最新の取り組みをご紹介します。

#### イベント時系列解析

イベントの発生タイミング(時刻)を記録したデータはイベント時系列データと呼ばれ、地震、機器故障、消費者の購買、SNS投稿、さらには心拍(心臓の拍動)など多様な現象がこの形式で日々蓄積されています。具体的には、イベント時系列データはイベントの発生時刻とそれに付随する情報のペアを単位とするデータであり、SNS投稿を例に取れば、前者は投稿時刻、後者は投稿者・文面・位置情報などが該当します。当該データはイベントの発生メカニズムを特定し、発生タイミン

グを精度良く予測する重要な手掛かりとなります。

イベントの発生タイミングは、時間軸上の点で表現されます。この「点」が確率的に発生する過程を記述する枠組みが「点過程」であり、機械学習と組み合わせることで、イベント時系列データを解析するための標準的な手法となっています。点過程では、単位時間当たりの発生確率である「強度関数」に従ってイベントが発生すると考えます。すなわち、強度関数が大きい時間帯では発生が集中し、小さい時間帯では散発的になります。さらに、強度関数に履歴依存性(過去のイベントの影響)を組み込むことで、規則的あるいは群発的な挙動も表現できます(図1左)。この強度関数は機械学習によってデータから学習可能であり、その学習結果を用いることで、様々なイベント時系列の予測が実現できます(図1右)。

#### 強度関数の学習

機械学習に基づく関数学習には、関数モデルの構造を定めてモデルパラメータを学習する手法と、データに応じて関数モデルの構造自体を柔軟に学習する方法があります。前者は深層学習、後者はカーネル法がその代表例です。私たちは、関

数の形状に対する先入観の影響を受けにくい利点から、カーネル法による強度関数の学習(図2)に着目しています。

カーネル法では、データへの適合度を測る指標である損失関数の最小化を通じて関数を学習します。このとき、無限次元の自由度を持つ関数空間における最小化問題となるため、直接的には解くことができません。しかし、損失関数が特定の条件を満たす場合、効率的な求解が可能で有限次元の最小化問題に帰着できることが知られています。これが「表現性定理」であり、カーネル法の理論的基盤を成す概念です。ところが、この理論を強度関数の学習にそのまま適用することは困難です。なぜなら、点過程の損失関数に強度関数の時間積分項が含まれており、これが従来の表現性定理が想定する条件を満たさないためです。近年、この従来想定された条件が必ずしも本質的ではないことが指摘され、問題設定を適切に制限することで、点過程においても表現性定理が成立する事例が報告されています[1]。しかし、これらの手法はイベントの発生要因や履歴依存性を考慮できないなど適用範囲が限定的であり、なお多くの課題が残されています。

そこで私たちは、表現性定理が成立する点過程手法の開発に取り組んでいます。ここでは最近の成果を二点ご紹介します。第一に、イベント発生の外部要因(例:機器故障イベントに対する湿度や経年数)が強度関数に与える影響を学習可能な手法を構築しました[2]。外部要因を考慮して将来の強度関

数を評価することで、高精度なタイミング予測が可能となります。第二に、損失関数の工夫により、イベント予測の精度を維持しつつ学習の安定性と速度を大幅に改善する手法を構築しました[3, 4]。これにより、大規模データの解析やリアルタイムな予測への応用が可能になります。二点目については展示05番にて詳しくご説明します。

#### 今後の展望

データ収集基盤の発展により、利用可能なデータはますます大規模化しています。それに伴い、意思決定にはこれまで以上の精度と迅速性が求められています。こうした状況を踏まえ、私たちはイベント時系列解析のさらなる高精度化と高速化に取り組んでいきます。その先に見据えるのは、タイミングの予測を超えた「制御」、すなわち、特定した発生要因に介入し、将来のイベント発生を望ましい方向へ導く技術の構築です。その取り組みはまだ端緒に就いた段階ですが、その一環として、日々の健康行動達成を支援するプログラムにおいて、参加者の「未達イベント」を減らす介入戦略の学習に取り組んでいます[5]。今後は、予測を基盤としつつ、制御を含む統合的な枠組みへと発展させ、イベント時系列解析の社会実装をめざします。

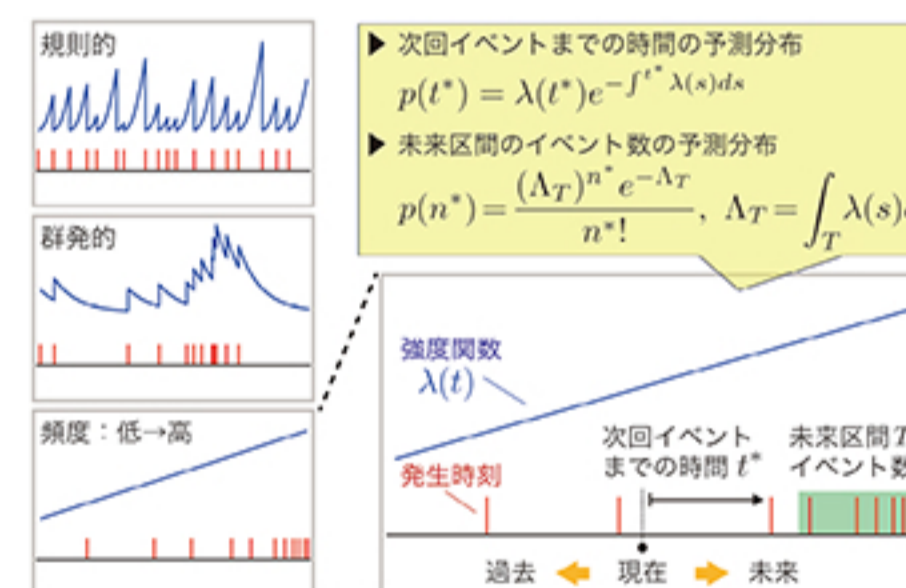


図1: イベントの発生パターンの例(左)と代表的なイベント予測(右)

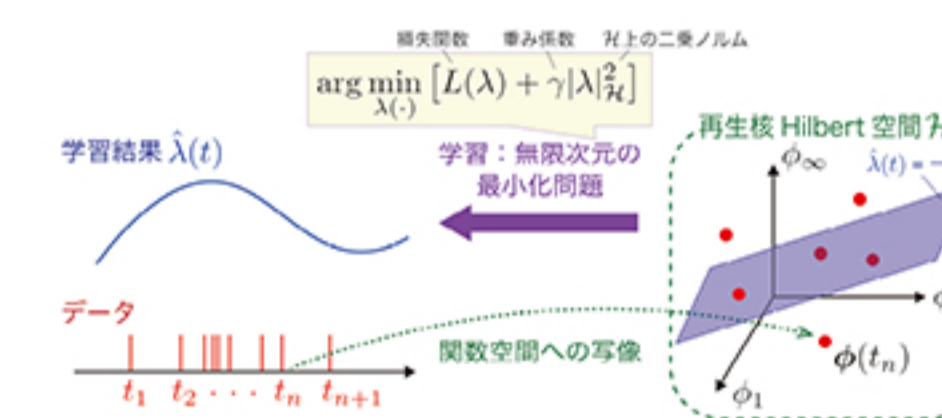


図2: カーネル法に基づく強度関数の学習

#### ●参考文献

- [1] S. Flaxman, Y. W. Teh, D. Sejdinovic, "Poisson intensity estimation with reproducing kernels," in *Proc. 20th International Conference on Artificial Intelligence and Statistics (AISTATS)*, 2017.
- [2] H. Kim, "Survival permanental processes for survival analysis with time-varying covariates," in *Advances in Neural Information Processing Systems (NeurIPS)*, 2023.
- [3] H. Kim, T. Iwata, A. Fujino, "K<sup>2</sup>E: Kernel method-based kernel intensity estimators for inhomogeneous Poisson processes," in *Proc. 42nd International Conference on Machine Learning (ICML)*, 2025.
- [4] H. Kim, T. Iwata, "A representer theorem for Hawkes processes via penalized least squares minimization," in *Proc. 14th International Conference on Learning Representations (ICLR)*, 2026.
- [5] H. Kim, T. Kurashima, "Effective strategy of financial incentive for exercise adherence," *Jxiv* 298, 2023.