

令和 7 年度 (2025) 共同利用研究・研究成果報告書

研究課題名	和文：陽子崩壊 $p \rightarrow \nu K^+$ の研究 英文：Study of proton decay $p \rightarrow \nu K^+$
研究代表者	三浦 真（東大宇宙線研）
参加研究者	早戸 良成（東大宇宙線研）
研究成果概要 陽子崩壊 $p \rightarrow \nu K^+$ の解析では、$K^+ \rightarrow \nu \mu^+$ の崩壊モードで脱励起時に放出されるガンマ線を用いてバックグラウンド (BG) を低く押さえて、粒子の運動量やガンマ線とミューオンの時間差などの物理量にカットを施すことによりイベントの抽出を行ってきた。しかし、$K^+ \rightarrow \nu \mu^+$ のbranching ratioがおよそ64 %で、そのうち 6 MeVの脱励起ガンマ線を放出する割合が約40 %のため、検出効率は 25 %以下に制限されてしまう。また、6 MeVのガンマ線によるPMTのヒット数は少ないため、ミューオンと時間差が小さい場合はミューオンによるヒットに埋もれてしまい、実際の検出効率は 約 9 %まで下がってしまう。 検出効率の向上を目指して、機械学習を解析に応用することを検討している。手始めに Boosted Decision Tree (BDT) を用いてみた。従来の方法では、ミューオンの検出時間、ガンマ線の検出時間、ミューオンの運動量、ヒット情報を用いたgoodness、時間情報を用いたgoodness、ガンマ線候補のヒット数などにカットをかけてイベントを選出してきたが、これらの情報をBDTの入力に用いて機械学習を行い、信号とBGの分別を行ってみた。以下の図で紫の線はBDTの出力で、横軸が信号を選択する効率、縦軸がBGを排除する割合である。赤の点が従来の方法を用いた場合の結果である。同じBGを排除する割合で比較すると、従来の方法では$18.3 \pm 0.1 \%$ に対してBDTを用いた場合は$18.8 \pm 0.4 \%$ で、期待されていたような有意な改善は見られなかった。これは、ガンマ線の物理量を再構成するのがそもそも難しく、それらを入力とした機械学習では改善が難しいことを示唆していると考えられる。次のステップとして、物理量を入力とせず、信号のイメージそのものを利用するCNN, GNNなどといった手法を検討する。	




図 BDTの出力。横軸Efficiency、縦軸BG rejection rate。