

# 深層学習による超新星爆発からの重力波の検出

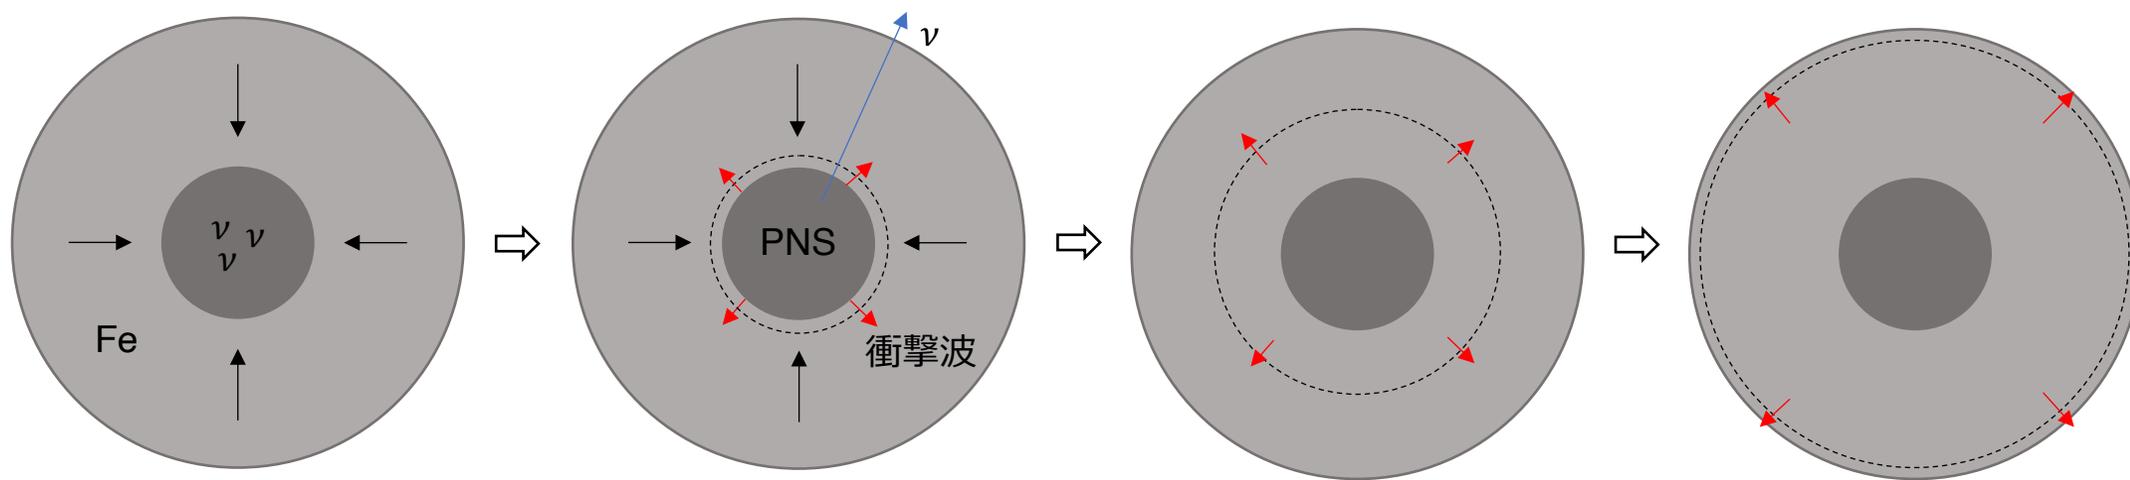
---

日本物理学会2022年秋季大会 9月7日 7pA122-14

笹岡聖也, Hou Yilun, Diego Dominguez, 宗宮健太郎, 高橋弘毅<sup>A</sup>  
東工大理, 東京都市大<sup>A</sup>

# 重力崩壊型超新星爆発

- 8太陽質量以上の恒星が起こす爆発
- 中性子星の形成過程
- 重力波の観測によって内部コアの物理を知ることができる



重力崩壊  
ニュートリノ閉じ込め

コアバウンス

PNS: 原始中性子星

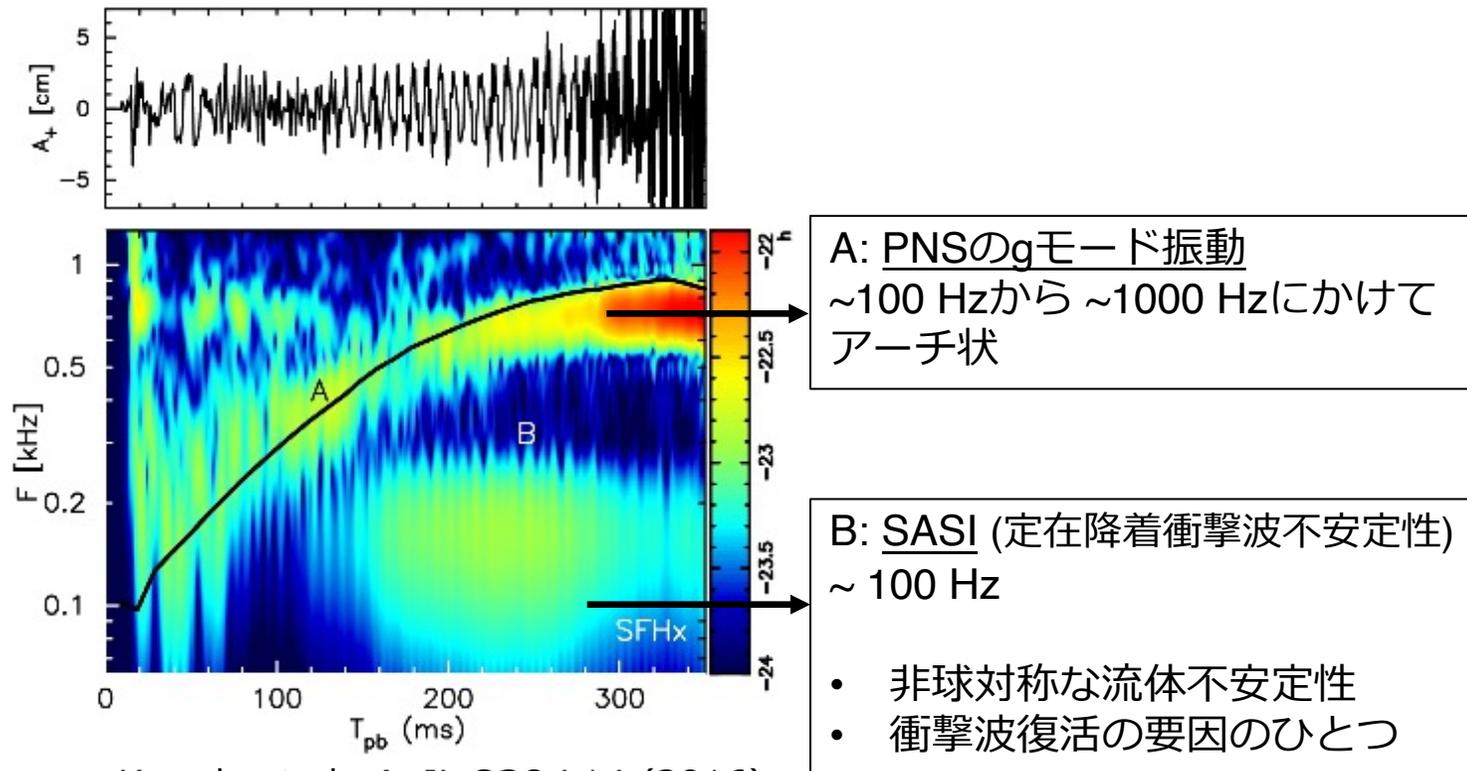
衝撃波の停滞

ニュートリノ加熱

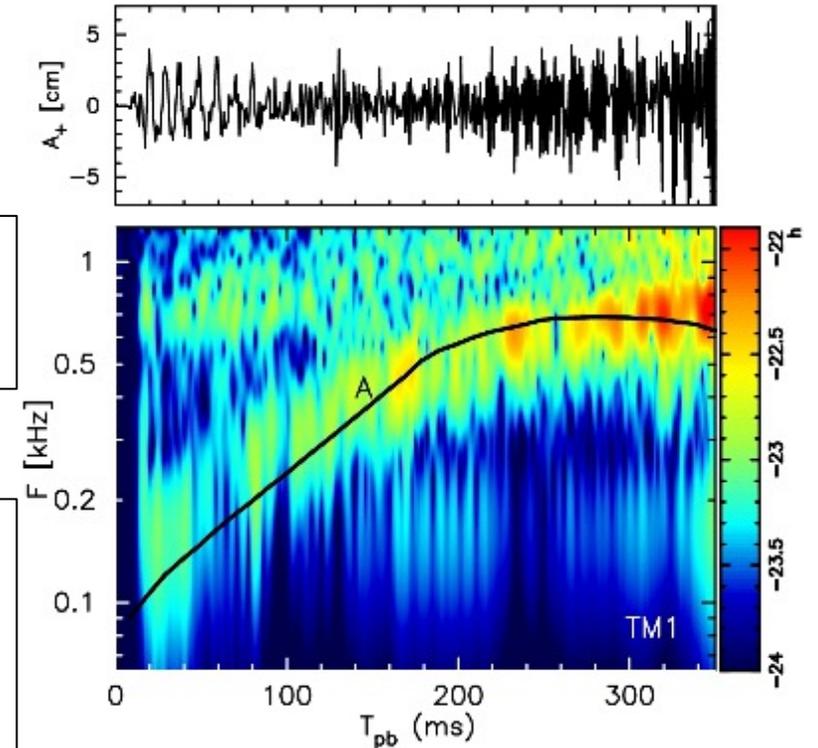
衝撃波の復活 → 爆発

# 重力波の波形

- 数値シミュレーションにより、時間周波数表現における共通の特徴が分かってきている



Kuroda et al., ApJL **829** L14 (2016)



EoSによってはSASIが起きない  
こともある

# 探査手法

波形の正確な予測が困難 → マッチドフィルタは使えない

- coherent WaveBurst (cWB)
    - Wavelet 変換を用いて、複数の検出器間でコヒーレントに発生する時間周波数領域の excess powerを見る
  - 深層学習ベース: López et al., PRD 103, 063011 (2021)など
    - gモードのphenomenological波形を用いてCNNを学習
    - シミュレーション波形を用いてテスト
- 本研究: SASIを加えたphenomenological波形で学習し、比較

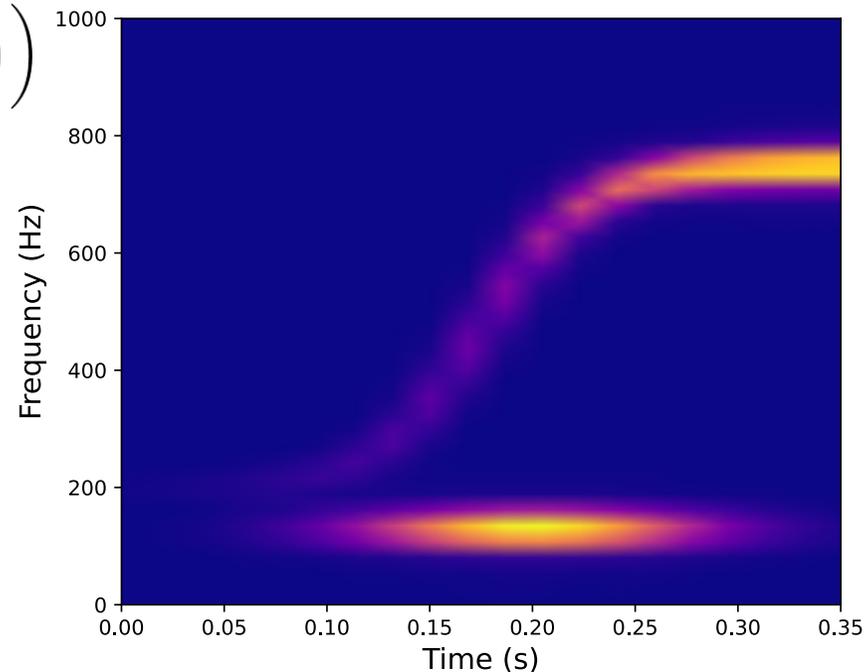
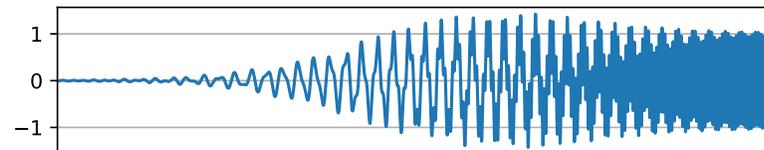
# phenomenological波形

$$h(t) = \underbrace{\exp\left[-\left(\frac{2\pi(t-t_g)}{\sigma_g^2}\right)^2\right]}_{\text{gモード}} \cos \phi(t) + r \underbrace{\exp\left[-\left(\frac{2\pi(t-t_s)}{\sigma_s^2}\right)^2\right]}_{\text{SASI}} \sin(2\pi f_s t)$$

$$\phi(t) = 2\pi \left( \frac{f_{\max} + f_{\min}}{2} (t - t_g/2) + 0.05 \frac{f_{\max} - f_{\min}}{2} \log \left( \cosh \left( \frac{t - t_g/2}{0.05} \right) \right) \right)$$

各パラメータの範囲

		min	max
gモード	$t_g$	0.2	0.6
	$\sigma_g^2$	0.8	1.3
	$f_{\min}$	150	500
	$f_{\max}$	500	2000
比	$r$	0	1
SASI	$t_s$	$t_g - 2$	$t_g + 2$
	$\sigma_s^2$	0.4	0.7
	$f_s$	100	150

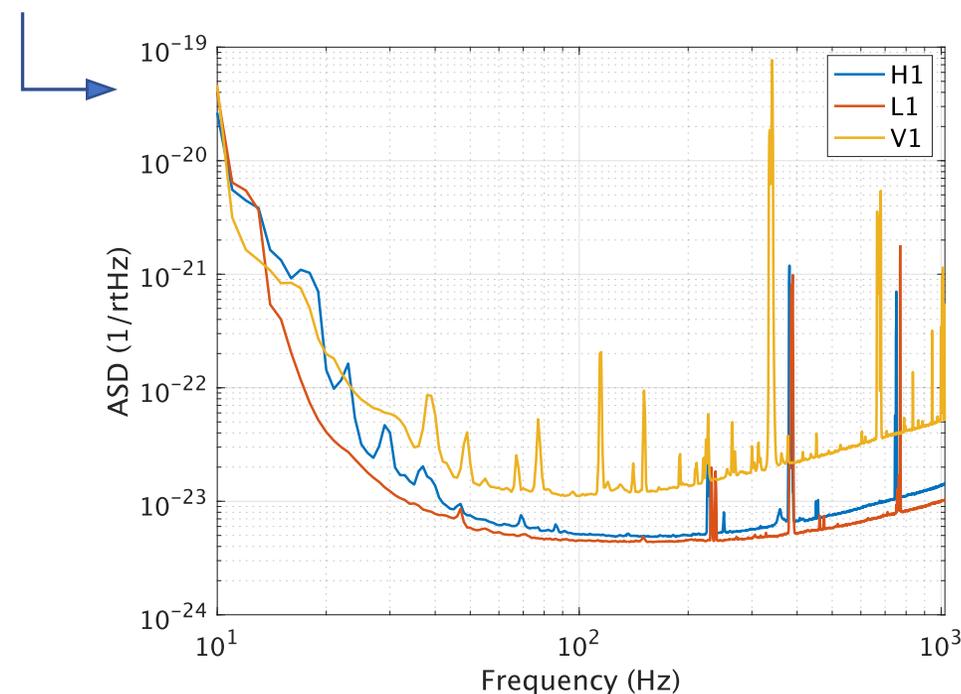


$t_g = 0.35, \sigma_g^2 = 1, f_{\min} = 200, f_{\max} = 750$   
 $r = 1, t = 0.2, \sigma_s^2 = 0.5, f_s = 130$  の場合

# 訓練データ

- ノイズ
  - PSD: O3のデータ\* からWelchの方法で推定
  - ガウシアンノイズ
- 信号
  - phenomenological波形
  - サンプリングレート4096Hz, 1秒分
  - 到来方向: ランダムに選択
  - SNR: [5,30]からランダムに選択
  - ホワイトニング

\* GWOSCからダウンロードした  
GPS時1238614016から4096秒分のデータを使用



→ 計100万個 (信号+ノイズ:50万, ノイズのみ: 50万)

# テストデータ

- 3次元シミュレーション波形

	SASIあり	SASIなし
Kuroda 2016	SFHx	TM1 DD1
Powell 2020	s18	m39 y20
Radice 2019	s25	s9 など

- 前処理

- 等間隔にリサンプリング
- ハイパスフィルタ
- tukey窓
- ゼロパディング

- 距離: [1, 3, 5, 7, 9, 11, 13, 15, 17, 19] kpc

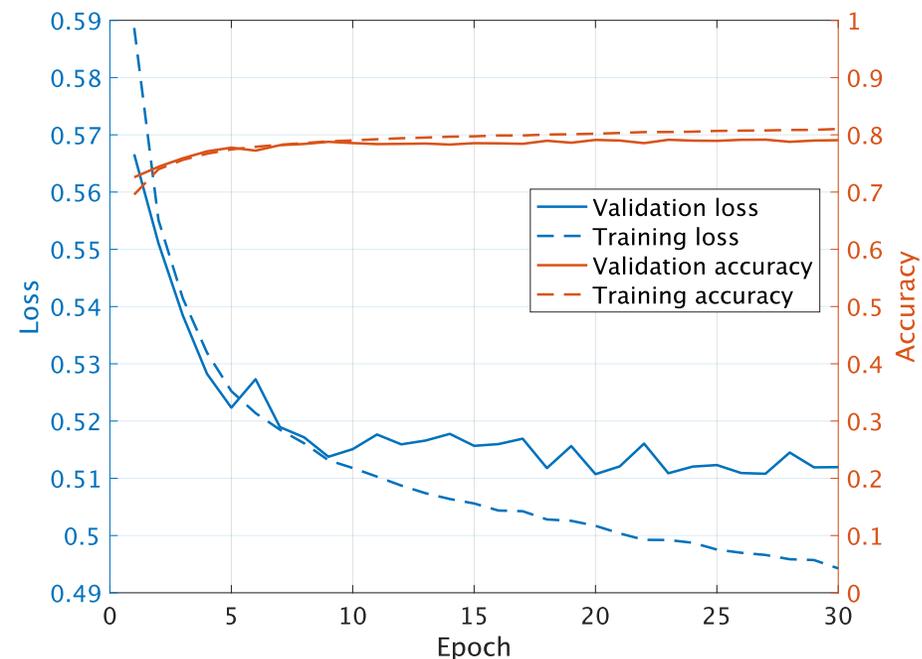
四重極モーメントが分かっているデータはあらゆる方向からの振幅を計算

# CNNモデル

- ホワイトニングした時系列信号を入力とする1次元CNN
- Gabbard et al. (2018)のモデルをもとに作成  
カーネルサイズや活性化関数を変更

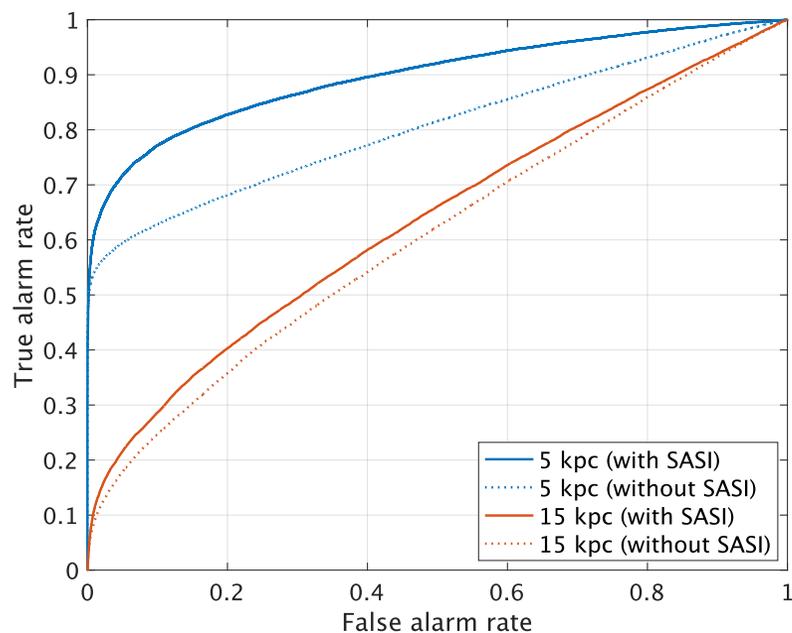
Layer	Input	1	2	3	4	5	6	7	8	9
Type		Conv	Conv	Conv	Conv	Conv	Conv	Linear	Linear	Linear
Size	(3,4096)	(16,4033)	(16,992)	(16,961)	(16,310)	(16,295)	(16,140)	64	64	2
Kernel size		64	64	32	32	16	16	-	-	-
Maxpool size		-	4	-	3	-	2	-	-	-
Dropout		0	0	0	0	0	0	0.25	0.25	0
Activation		SiLU	SiLU	SiLU	SiLU	SiLU	SiLU	SiLU	SiLU	Softmax

パラメータ数: 191,842



# テスト結果 (ROCカーブ)

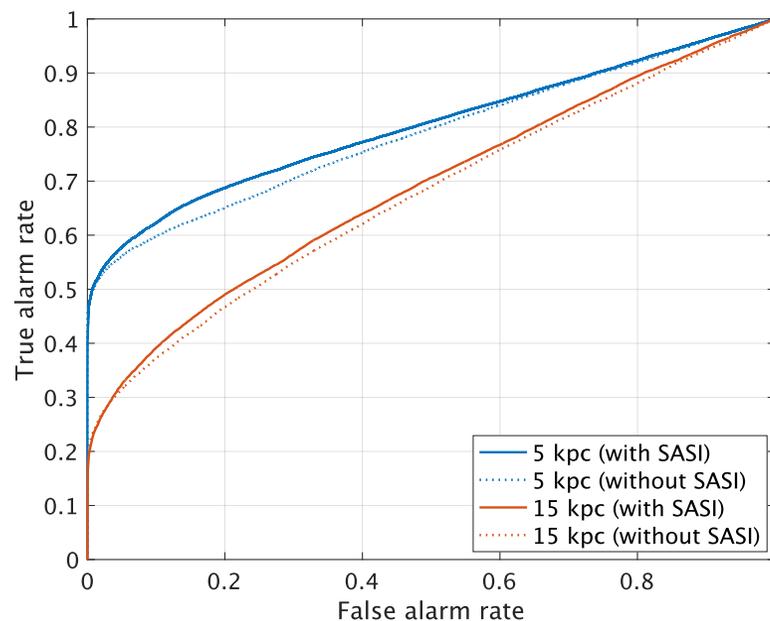
テストデータ1: SASIが現れたシミュレーション波形



AUC (ROCカーブ下の面積)

	5 kpc	15 kpc
SASIありで学習	0.897	0.671
SASIなしで学習	0.805	0.644

テストデータ2: SASIが現れなかったシミュレーション波形



AUC

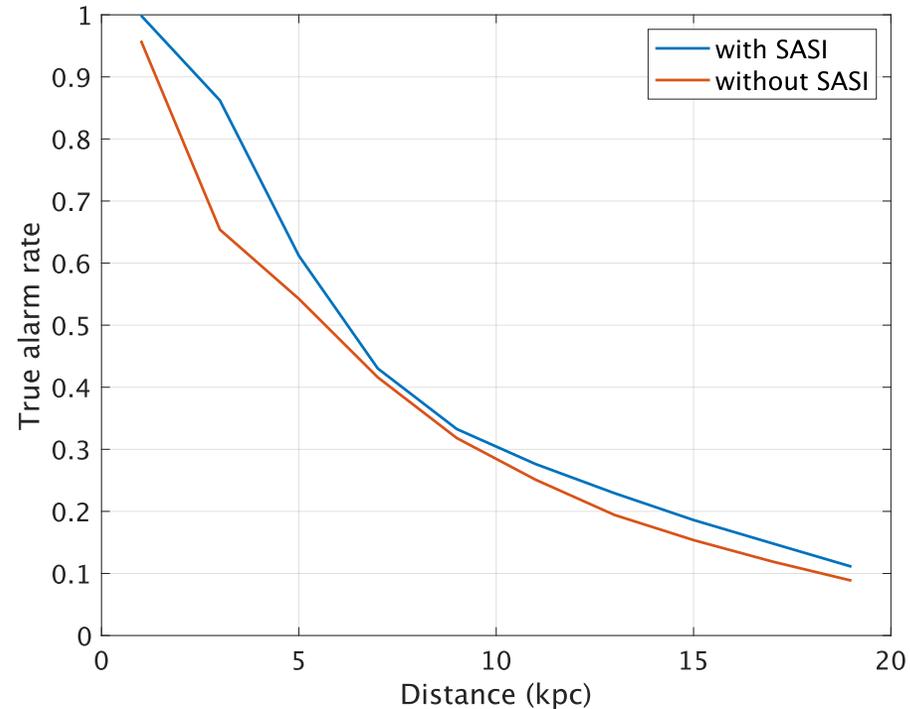
	5 kpc	15 kpc
SASIありで学習	0.800	0.686
SASIなしで学習	0.786	0.672

実線: SASIを加えた波形で学習  
点線: gモードのみの波形で学習

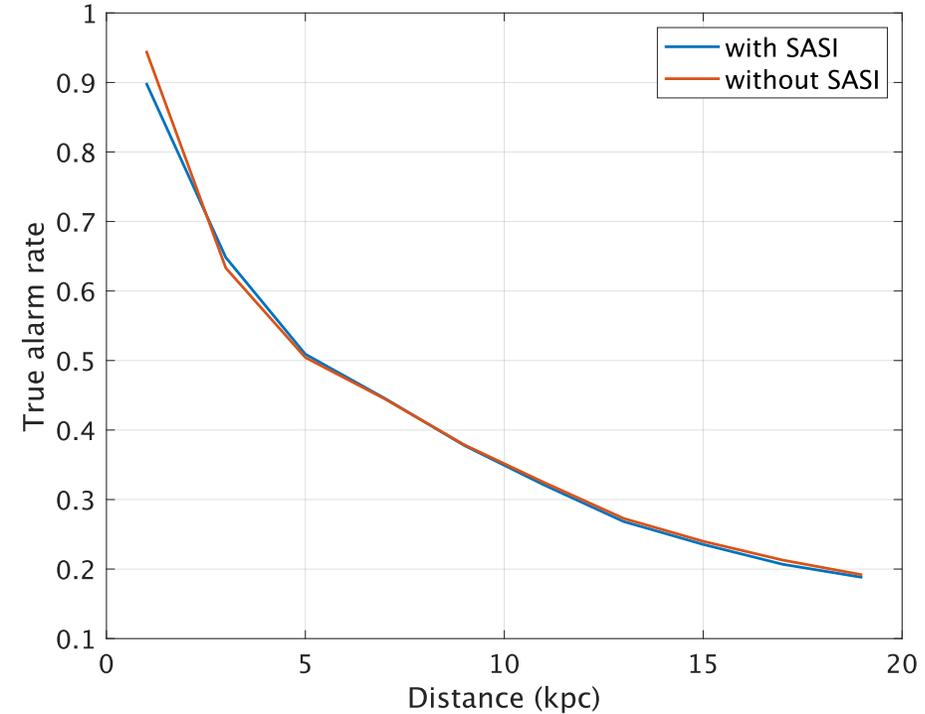
- SASIを加えた波形で学習することでSASIが現れた波形での精度が向上
- SASIが現れなかった波形での精度もわずかに向上

# 距離に対する検出可能性

テストデータ1: SASIが現れたシミュレーション波形



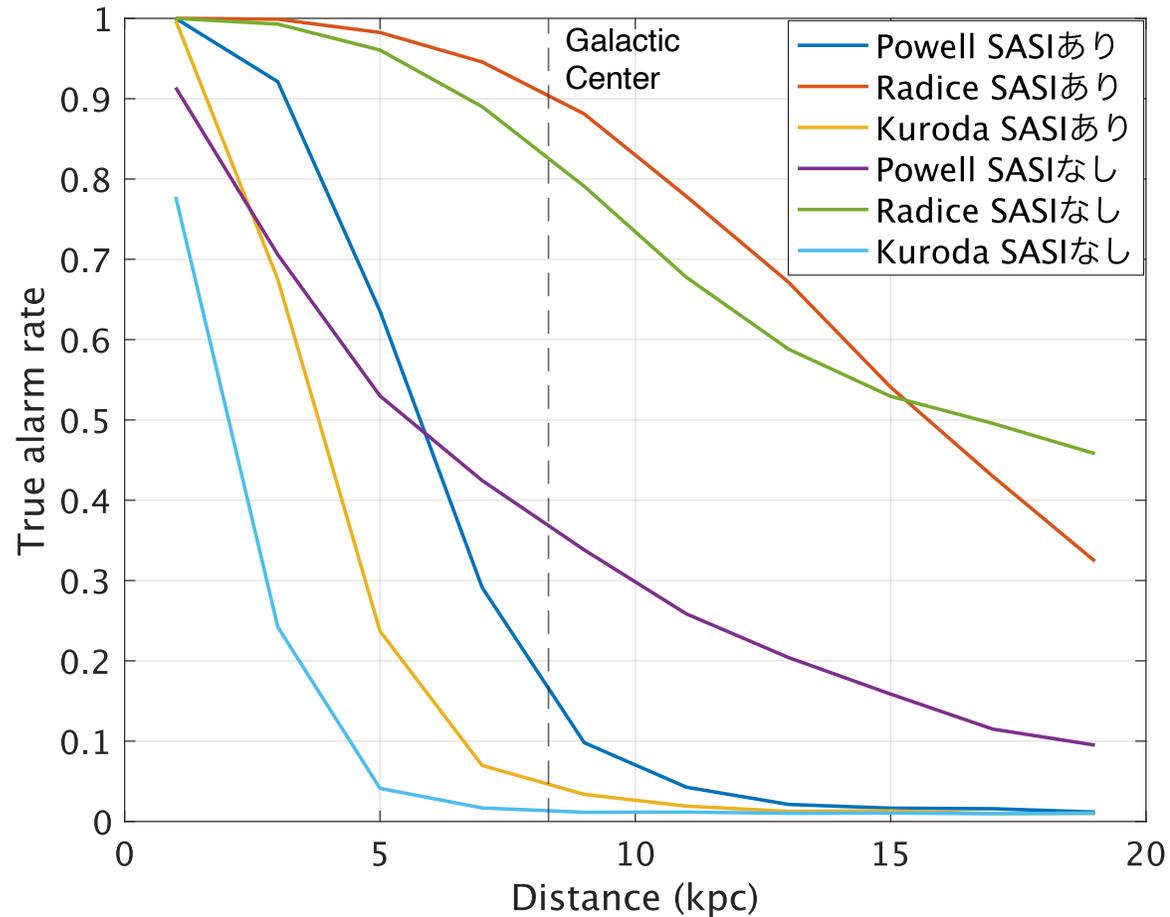
テストデータ2: SASIが現れなかったシミュレーション波形



FAR: 0.01に固定

- SASIを含む波形で学習することでSASIが現れた波形に対して各距離での真陽性率が向上
- SASIが現れなかった波形に対してはほとんど変化なし

# 各波形の検出可能性



SASIありのモデルでテスト  
FAR: 0.01に固定

- Radice 波形に対する精度は良い
- Kuroda 波形の精度が良くない → 波形パラメータや式を再考したい

# まとめ

- SASIを加えたphenomenological波形でCNNを学習
- SASIが起きたシミュレーションデータに対して検出精度が向上
- SASIが起きなかったデータに対してもわずかに精度が向上

## 今後の展望

- phenomenological波形のパラメータ再考
- 2次元CNNを用いて精度向上
- 実ノイズとガウシアンノイズの比較
- cWBとCNNの比較 (精度, 速度)

# Backup

深層学習ベースの探査手法の先行研究

	Astone et al. (2018)	López et al. (2021)	less et al. (2021)	Chan et al. (2020)
トレーニング・テスト波形	phenomenological波形 (g-modeに着目)	<ul style="list-style-type: none"> <li>phenomenological波形 (g-modeに着目)をアップデート (パラメータ数増など)</li> <li>テスト波形として <b>neutrino-driven CCSN</b>波形も利用</li> </ul>	<ul style="list-style-type: none"> <li><b>neutrino-driven CCSN</b>波形</li> <li>モデル化した<b>グリッチ</b>波形 (Sine-gaussian と Scattered light)</li> </ul>	<ul style="list-style-type: none"> <li><b>magnetorotational CCSN</b> 波形</li> <li><b>neutrino-driven CCSN</b> 波形</li> </ul>
ノイズモデル	LIGO, Virgo の シミュレーションノイズ (3台構成)	LIGO, Virgoの シミュレーションノイズ (Astone et al. との比較のため) <b>O2の実ノイズデータ</b> (3台構成)	Adv. Virgo (O3) or ET の シミュレーションノイズ (1台構成)	<ul style="list-style-type: none"> <li><b>LIGO 2台, Virgo, KAGRA (HLVK)</b></li> <li><b>LIGO A+ (Hanford, Livingston), V, K</b> シミュレーションノイズ</li> </ul>
CNNモデル	2D-CNN 2クラス分類： ノイズ 信号+ノイズ	<b>Mini Inception-Resnet</b> 2クラス分類： ノイズ 信号+ノイズ	1D-CNNと2D-CNN 2クラス分類： 信号 グリッチ  <ul style="list-style-type: none"> <li><b>1D-CNNと2D-CNNのアンサンブル：Multi-model</b> 分類の可能性を調査</li> </ul>	1D-CNN 3クラス分類： <b>magnetorotational</b> 信号+ノイズ <b>neutrino-driven</b> 信号+ノイズ ノイズ
前処理などの特徴	<ul style="list-style-type: none"> <li>cWB を使用して time-frequency image を作成</li> <li>Image はそれぞれの検出器データで作成しRGBとして扱う</li> </ul>	Astone et al. (2018)と同等	<ul style="list-style-type: none"> <li>Wavelet Detection Filter を使用して trigger 情報を作成</li> </ul> <p>入力： 1D-CNN: trigger 周りのホワイトニングされた時系列データ 2D-CNN: trigger 周りの時間周波数 image (spectrogram)</p> <p>トレーニングに使用していない<b>model</b>をテスト<b>model</b>として使用している場合も評価</p>	<p>入力： ホワイトニングされた<b>各検出器の時系列データ</b></p> <p>トレーニングに使用していない<b>model</b>をテスト<b>model</b>として使用している場合も評価</p>

