

Synthetic Clinical Trial Data while Preserving Subject-Level Privacy


Mandis Beigi, PhD¹, Afrah Shafquat, PhD¹, Jason Mezey, PhD², Jacob Aptekar, MD, PhD¹

¹Medidata, New York, NY, USA, ²Cornell University, Ithaca, NY, USA

Motivation: Around 23,000+ clinical trials, 6.3M+ subjects are exclusively available to Medidata. This data is valuable for research and drug development but is siloed data due to privacy concerns and HIPAA regulations. Generating synthetic data will provide the means for data sharing. It also allows us to up-sample under-represented populations as well as augmenting the training data when datasizes are limited.

Synthesis Method:

- Co-segregation of attributes
- Truncated gaussian noise
- Multivariate outlier detection and removal
- K-anonymity check
- Multi-sponsor patient generation




Fidelity Evaluation:

Compared with four State-of-the-art synthesizers from the SDGym benchmark: GaussianCopulaGAN, TVAE, CopulaGAN and CTGAN.

Tested on four clinical trial datasets ranging from 698 to 4369 patients as well as other canonical datasets from the benchmark.

To compare the synthesized data with the original, we performed univariate tests such as the chi-square and Kolmogorov-Smirnov tests as well as bivariate tests and multivariate tests such as bag-of-words and silhouette coefficients.



F. Fidelity quantification summary

Category	Univariate	Bivariate	Multivariate	Clinical trial - specific		
	Dimensions where K-S, Chi-Square p<0.05	Correlation, mean absolute difference	Silhouette score	"Bag of Words" dist	log-rank Overall Survival K-M	log-rank Progression Free Survival K-M
Best	0/N	0	0	0	1	1
Worst	N/N	1	1	0	0	0
Dataset						
Algorithm						
Non small cell lung cancer	Our method 0/171	0.11	0.00	0.04	0.47	0.89
	GC GAN	56/171	0.08	0.00	0.11	8.75E-26 0.46
	TVAE	98/171	0.10	0.01	0.22	5.62E-16 0.39
	Cop. GAN	64/171	0.22	0.04	0.24	9.63E-08 9.03E-09
	CTGAN	58/171	0.20	0.03	0.24	0.56 0.6
	Our method	2/174	0.07	0.00	0.02	0.99 NA
Diffuse Large B Cell Lymphoma	GC GAN	88/174	0.09	0.01	0.21	3.31E-35 NA
	TVAE	94/174	0.12	0.03	0.16	3.82E-09 NA
	Cop. GAN	82/174	0.22	0.01	0.33	2.49E-04 NA
	CTGAN	83/174	0.22	0.02	0.32	3.02E-11 NA
	Our method	11/142	0.08	0.00	0.01	NA NA
Acute Lymphoblastic Leukemia	GC GAN	72/142	0.20	0.03	0.26	NA NA
	TVAE	73/142	0.48	0.00	0.08	NA NA
	Cop. GAN	101/142	1.14	0.02	0.17	NA NA
	CTGAN	115/142	1.10	0.03	0.15	NA NA
	Our method	0/108	0.19	0.00	0.08	0.06 NA
Acute Myeloid Leukemia	GC GAN	36/108	0.29	0.01	0.19	0.68 NA
	TVAE	58/108	0.30	0.07	0.39	5.86E-35 NA
	Cop. GAN	44/108	0.42	0.03	0.30	0.11 NA
	CTGAN	36/108	0.42	0.02	0.31	0.20 NA

Privacy Evaluation:

A. Load source, R
B. Partition into R' and R-R'

● = Real record



C. Produce synthetic datasets, S(R-R') and S(R)

✗ = Synthetic record

S(R) S(R-R')

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗ ✗ ✗ ✗

✗ ✗