



BACHELOR THESIS
INSTITUTE FOR DESIGN
AND CONTROL OF
MECHATRONICAL
SYSTEMS

A-4040 LINZ,
ALTENBERGER STR. 69,
INTERNET:
[HTTP://DESREG.JKU.AT](http://desreg.jku.at)

STOCHASTISCHE GENERIERUNG VON MEDIZINISCHEN ZEITREIHEN

SUPERVISION: DR. PAVLO TKACHENKO

SEITE 1/19



ÜBERSICHT

- TYP 1 DIABETES
- AUFGABENSTELLUNG
- GAN
- KOSTENFUNKTIONEN
- MOTIVATION FÜR MODALES TRAINING
- GANS (MODAL, GRAPHISCH & NUMERISCH)
- INTERPRETATION (MODAL)
- TRAINIEREN MIT CGM
- GANS (CGM, GRAPHISCH & NUMERISCH)
- SCHLUSSFOLGERUNG
- AUSBLICK

TYP 1 DIABETES



PIXABAY

BLACK CONTOUR TS DISPLAYING AT 4.8

[HTTPS://WWW.PEXELS.COM/DE-DE/FOTO/GESUNDHEIT-MEDIZINISCH-MEDIZIN-STECHEN-46173/](https://www.pexels.com/de-de/foto/gesundheits-medizinisch-medizin-stechen-46173/)

[HTTPS://CREATIVECOMMONS.ORG/PUBLICDOMAIN/ZERO/1.0/LEGALCODE#LANGUAGE S](https://creativecommons.org/publicdomain/zero/1.0/legalcode#language-s)

- PANKREAS PRODUZIERT WENIG ODER KEIN INSULIN
- KONTINUIERLICHE DARSTELLUNG DES GLUCOSE-VERLAUFES IST VORTEILHAFT
- WEITERENTWICKLUNG DURCH MATHEMATISCHE ALGORITHMEN (VORHERSAGE-METHODEN)
- PRÜFUNG DER PERFORMANCE DURCH GENERIERTE DATEN




AUFGABENSTELLUNG

- ANALYSE DER LITERATUR UND DER DATENSÄTZE
- ENTWICKLUNG STANDARD GAN, LSGAN
- TRAINIEREN UND TESTEN AN UNIMODALEN UND MULTIMODALEN VERTEILUNGEN
- ENTWICKLUNG DRAGAN
- TRAINIEREN UND TESTEN AN UNIMODALEN UND MULTIMODALEN VERTEILUNGEN
- TRAINIEREN UND TESTEN AN GLUCOSE-VERLÄUFEN
- QUALITÄTSMBEWERTUNG (AUCH KLINISCHE KRITERIEN)
- DOCUMENTATION

GAN

- GENERATOR UND DISKRIMINATOR
- GENERATOR: ERZEUGT ZUFÄLLIGE AUSGABEN
- DISKRIMINATOR: BEURTEILT QUALITÄT DURCH VERGLEICH MIT REALEN VERLÄUFEN (KOSTENFUNKTION)
- GAN (STANDARD), LSGAN, DRAGAN
- TRAINING DURCH RÜCKFÜHRUNG



KOSTENFUNKTIONEN

■ Standard GAN

$$L_D^{GAN} = E[\log(D(x))] + E[\log(1 - D(G(z)))]$$

$$L_G^{GAN} = E[\log(D(G(z)))]$$

■ LSGAN

- Glatterer Gradient
- Bessere Kritik für Generator (Gradient ungleich null)

$$L_D^{LSGAN} = E[(D(x) - 1)^2] + E[D(G(z))^2]$$

$$L_G^{LSGAN} = E[(D(G(z)) - 1)^2]$$

■ DRAGAN


- Verwendet Gradienten-Ziele
- Wirkt Kollaps durch schlechte lokale Konvergenz entgegen

$$L_D^{DRAGAN} = L_D^{GAN} + \lambda E[(|\nabla D(\alpha x - (1 - \alpha x_p))| - 1)^2]$$

$$L_G^{DRAGAN} = L_G^{GAN}$$

MOTIVATION FÜR MODALES TRAINING

- Prüfung der Ergebnisse/Funktionalität
 - Konvergenz
 - Mode-Collapse




- Einfache bekannte Verläufe → Unimodal & Multimodal
- Graphische und numerische Qualitätsanalyse

STANDARD GAN

Input	
<u>unimodal</u>	multimodal
$\bar{x} \approx -4$	$\bar{x} \approx -4, 4$
$s \approx 0.5$	$s \approx 0.5, 0.5$

$$L_D^{GAN} = E[\log(D(x))] + E[\log(1 - D(G(z)))]$$

$$L_G^{GAN} = E[\log(D(G(z)))]$$




LSGAN

Input	
unimodal	multimodal
$\bar{x} \approx -4$	$\bar{x} \approx -4, 4$
$s \approx 0.5$	$s \approx 0.5, 0.5$

$$L_D^{LSGAN} = E[(D(x) - 1)^2] + E[D(G(z))^2]$$


$$L_G^{LSGAN} = E[(D(G(z)) - 1)^2]$$



DRAGAN

Input	
<u>unimodal</u>	multimodal
$\bar{x} \approx -4$	$\bar{x} \approx -4, 4$
$s \approx 0.5$	$s \approx 0.5, 0.5$

$$L_D^{DRAGAN} = L_D^{GAN} + \lambda E[(|\nabla D(\alpha x - (1 - \alpha x_p))| - 1)^2]$$
$$L_G^{DRAGAN} = L_G^{GAN}$$



NUMERISCHE ANALYSE

Input	
unimodal	multimodal
$\bar{x} \approx -4$	$\bar{x} \approx -4, 4$
$s \approx 0.5$	$s \approx 0.5, 0.5$

Standard GAN		LSGAN		DRAGAN	
unimodal	multimodal	unimodal	multimodal	unimodal	multimodal
$\bar{x} \approx -3.945$	$\bar{x} \approx -3.878, 4.404$	$\bar{x} \approx -3.977$	$\bar{x} \approx -3.995, 3.93$	$\bar{x} \approx -4.007$	$\bar{x} \approx -4.164, 3.41$
$s \approx 0.701$	$s \approx 0.825, 0.988$	$s \approx 0.532$	$s \approx 0.457, 0.684$	$s \approx 0.304$	$s \approx 0.474, 0.657$

INTERPRETATION (UNI-/MULTIMODAL)

- Standard Gan


- ❖ Discriminator ist stärker als Generator
- ❖ Ansonsten wären die generierten Daten überspitzt
- ❖ Problem bei multimodalem Input

- LSGAN

- ❖ Zusätzlicher Hidden Layer ist nicht erforderlich
- ❖ Erfasst alle Abweichungen



- DRAGAN

- ❖ Erweiterung von Simple GAN
- ❖ Discriminator ist stärker als Generator (unimodal trotzdem überspitzt)
- ❖ Multimodaler Input wird besser erfasst





TRAINIEREN MIT CGM



Aufbereitung der Input-Daten und Filterung der Output-Daten:





SIMPLE GAN (CGM, GRAPHISCH)



LSGAN (CGM, GRAPHISCH)



DRAGAN (CGM, GRAPHISCH)



Parameter	Simple GAN	LSGAN	DRAGAN	Input
j-index	41.297	36.168	34.304	35.818
cv	0.186	0.252	0.172	0.305
MBG	172.582	153.309	158.936	142.355
HBGI	8.001	7.435	5.719	4.908
LBGI	0.323	4.940	0.504	1.862
GRADE	2.018	9.086	1.579	2.354
grade_hypo	2.586	27.219	5.704	22.900
grade_hyper	72.922	52.566	51.056	37.644
grade_range	24.492	20.215	43.240	39.456
Range	120.954	127.160	118.604	196.166

Tabelle 2: Mittelwerte der medizinischen Parameter der letzten 100 GAN-Ausgaben

Parameter	Simple GAN	LSGAN	DRAGAN	Input
j-index	6.047	17.558	6.699	15.723
cv	0.088	0.171	0.088	0.084
MBG	24.256	57.096	25.400	30.304
HBGI	3.394	6.646	3.077	4.351
LBGI	0.900	10.198	1.185	1.621
GRADE	0.813	18.487	0.869	1.453
grade_hypo	11.394	39.304	16.154	24.544
grade_hyper	20.924	40.315	26.082	29.666
grade_range	16.172	20.329	21.321	22.177
Range	38.110	51.439	37.476	58.364

Tabelle 3: Standardabweichungen der medizinischen Parameter der letzten 100 GAN-Ausgaben

NUMERISCHE ANALYSE

CGM-DATEN

SCHLUSSFOLGERUNG

- Training war erfolgreich
- Simple GAN: einfach, solide, zufriedenstellend
- LSGAN: vielschichtig, teilweise unrealistisch
- DRAGAN: weniger variantenreich, gute ergebnisse

AUSBLICK

- Resultate sind vielversprechend
- Optimierungsbeispiele:
 - Filterung der Outputs
 - Vermischung der Outputs
 - Trainingsdauer
 - Separiertes Training mit CGM-Daten von Patientengruppen
- Verwendung:
 - Generierung von ausreichend Daten (zufallsauswahl)
 - Automatisierung des Prozesses (Blackbox)