



Retrospektive Detektion von Mahlzeiten in Diabetesdaten

Lukas Schubert

Betreuer: Dr. Florian Reiterer

Diabetes

- Diabetes:
 - chronische Krankheit mit erhöhter Blutglukosekonzentration
 - Gestörter Stoffwechsel von Kohlenhydraten, Fetten und Proteinen
- Typ1 Diabetes:
 - β -Zellen werden durch eine Auto-Immun Reaktion zerstört
 - Insulinmangel
 - 10% der Fälle
- Typ2 Diabetes:
 - Reduzierte Insulinsensitivität
 - Geringere Produktion von Insulin
 - 90% der Fälle

SOGMM Modell

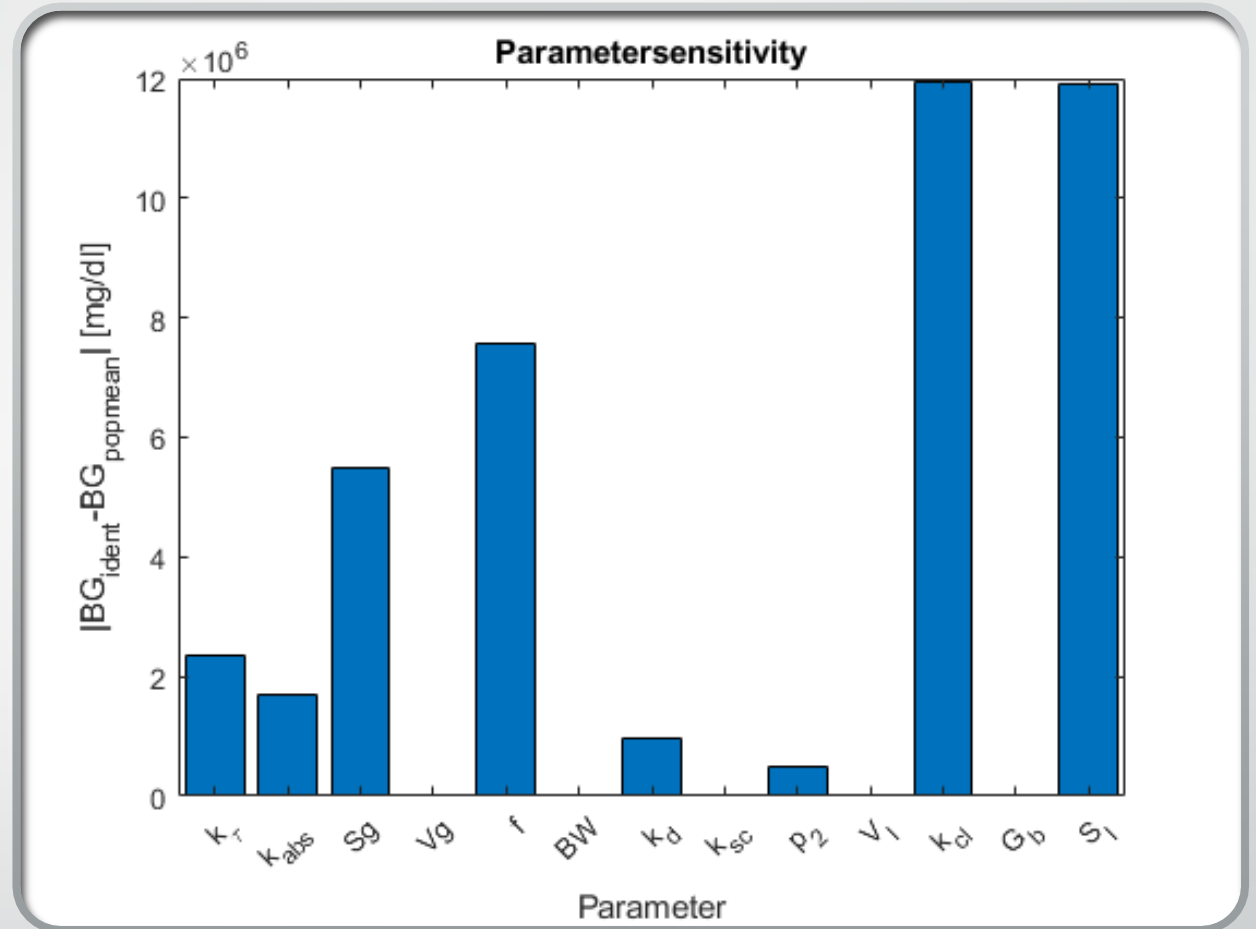
- Subcutaneous Oral Glucose Minimal Model
- Kompartiment Modell
- 2 Eingänge (Kohlenhydrate und Insulin)
- 8 Zustände

Parameteridentifikation

- 13 Parameter
- Optimieren der Parameter durch Minimierung einer Kostenfunktion
 - Langsam da Optimierungsproblem
- Einfache Identifikation durch Patientendaten möglich?

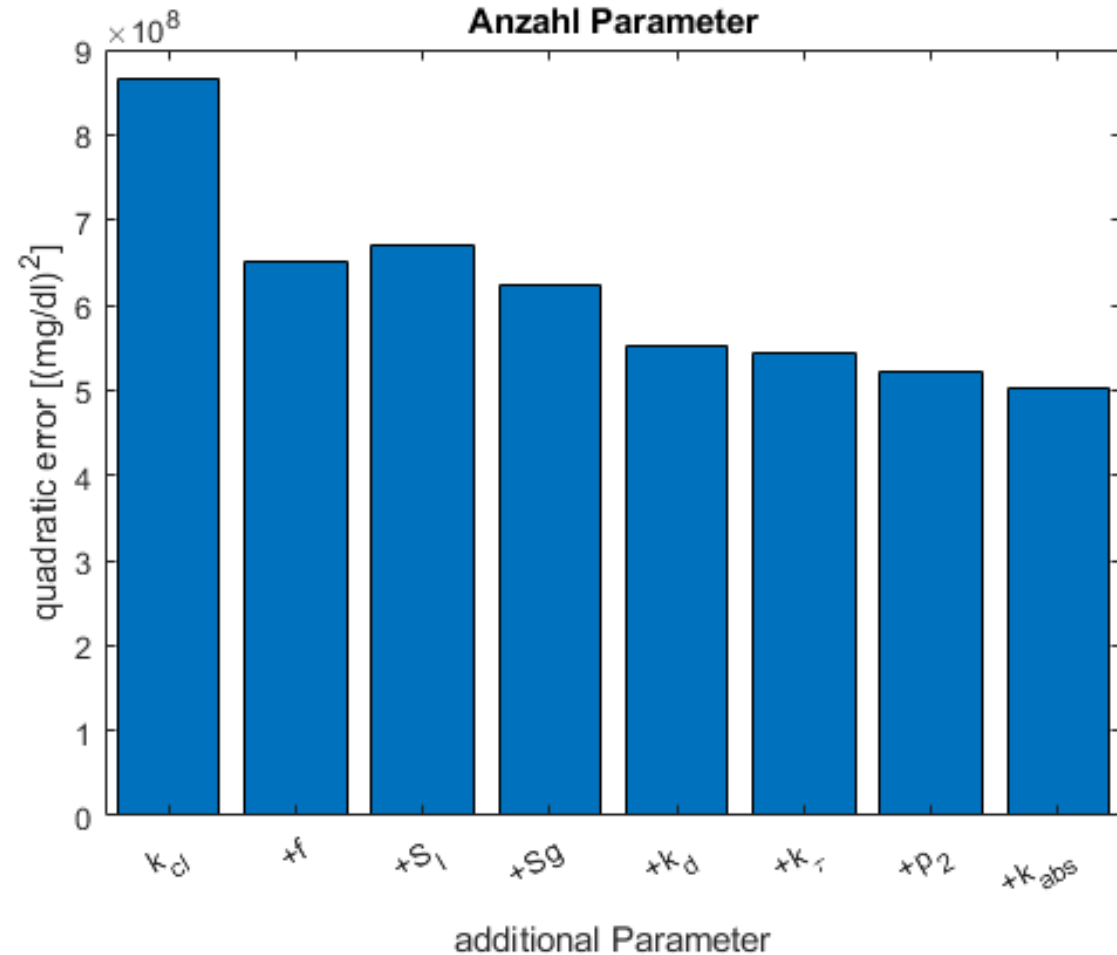
Parametersensitivität

- Änderung der Kosten durch Optimieren eines einzelnen Parameters
- Große Änderung = hohe Sensitivität




Anzahl Parameter

- Wert der Kostenfunktion nach Optimierung mit unterschiedlicher Anzahl an Parametern
- Parameter in der Reihenfolge nach höchster Sensitivität hinzugefügt
- Im Schnitt für mehr als 4 Parameter keine signifikante Änderung



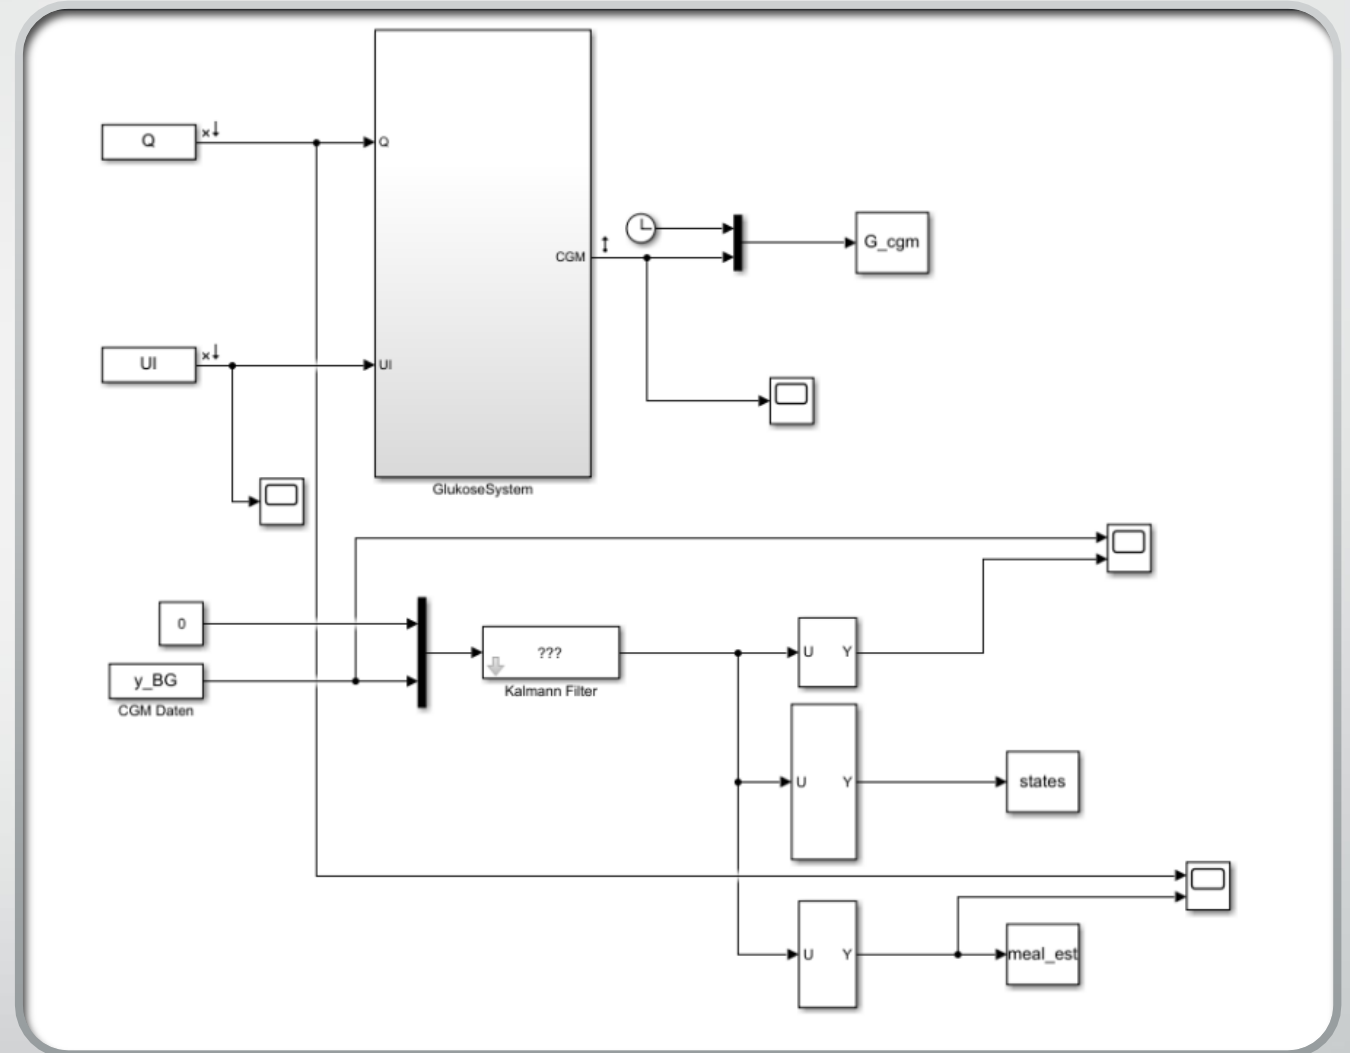
Korrelation

- Korrelation der identifizierten Parameter mit den Patientendaten
- Leider keine Korrelation feststellbar
- => weiterhin Verwendung der Populationsmittelwerte



Modellbasierte Detektion von Mahlzeiten

- Schätzen der Systemzustände zu jedem Zeitpunkt mittels Kalman Beobachter
- Simulation dieser Zustände 60min in die Zukunft
- Vergleich der prädizierten Blutzuckerwerte mit den CGM Messdaten



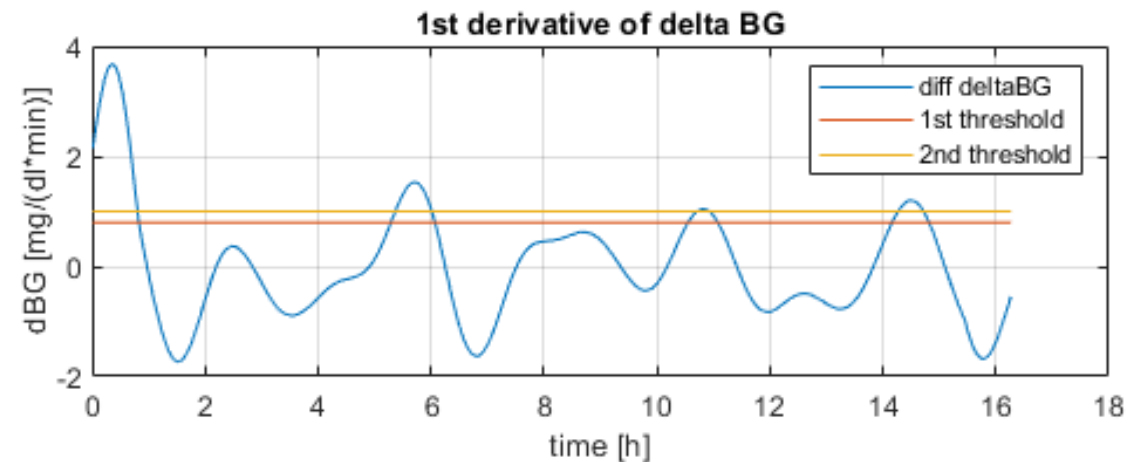
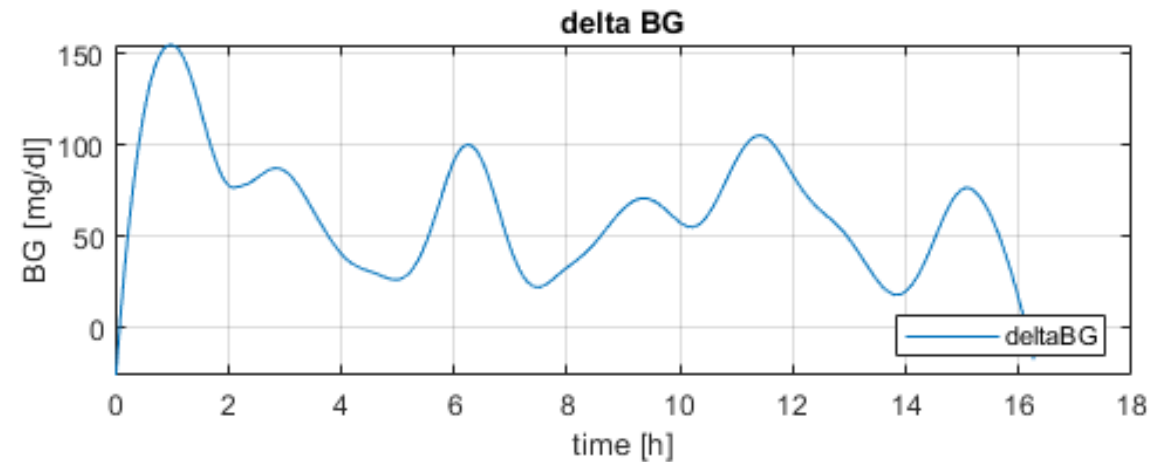
Prädiktion mit RICAM-Algorithmus

- Selbstlernender Algorithmus
- Auswahl des passenden Kernels
- Anpassung eines Regularisierungsparameters

Detektion

- Filterung der Daten mit Savitzky Golay Filter
- Mahlzeit wird detektiert wenn:
 - 1te Ableitung der Differenz einen Schwellwert überschreitet
 - Sinkt die Ableitung ab, bleibt jedoch über dem Schwellwert, so wird bei Überschreiten eines 2ten Schwellwerts erneut eine Mahlzeit detektiert

Lukas Schubert



09/23/2019

Example Day

Nr of meals: 4.00 ± 0.00

TP: 4.00 ± 0.00

FP: 0.00 ± 0.00

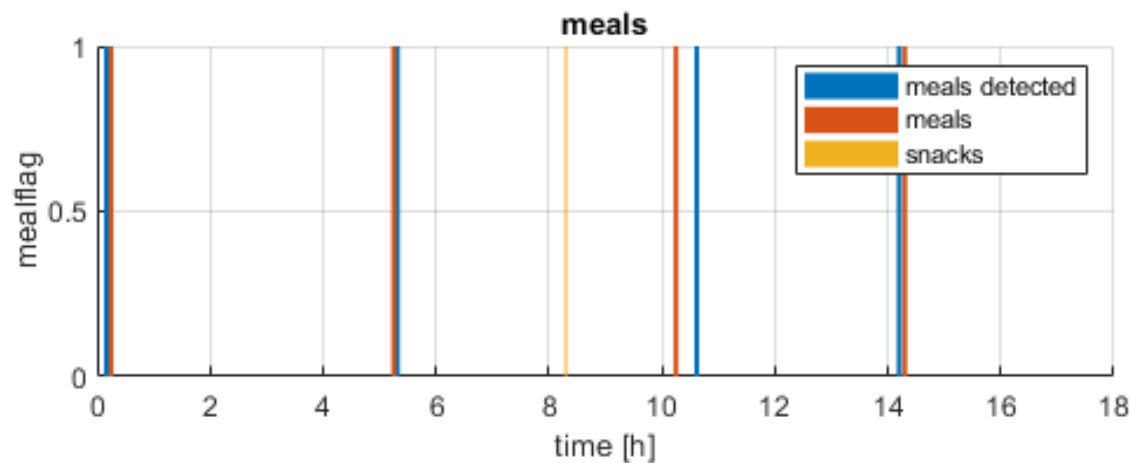

FN: 0.00 ± 0.00

sensitivity: 100.00% ± 0.00%

F1_Score: 1.00 ± 0.00

Nr of snacks: 1.00 ± 0.00

TP snacks: 0.00 ± 0.00



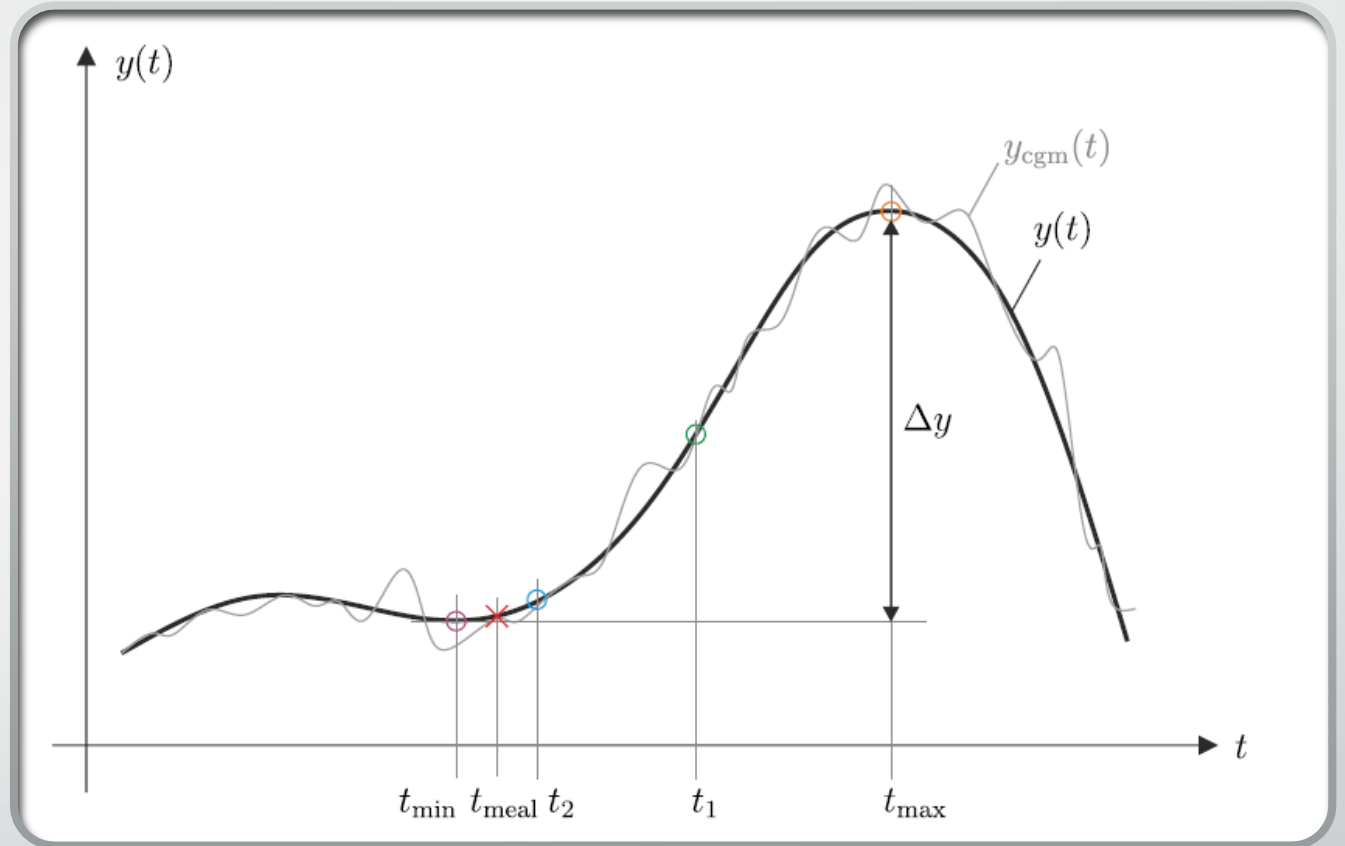
Vergleich mit anderen Ansätzen

- Harvey Online Algorithmus:
 - Filterung der CGM Daten mittels Tiefpassfilter
 - Berechnen der ersten Ableitung
 - Mahlzeitenerkennung bei überschreiten von Grenzwerten
 - 120min Pause nach einer Detektion

Vergleich mit anderen Ansätzen

- Heuristischer Ansatz:
 - Filterung (Savitzky Golay Filter)
 - t_{\min} : lokales Minimum
 - t_{\max} : lokales Maximum
 - t_1 : größte Steigung
 - t_2 : größte Krümmung
 - $\Delta y = y(t_{\max}) - y(t_{\min})$
 - $\Delta y > \Delta y_{\min}$ & $y_{\dot{}}(t_1) > y_{\dot{}}_{\min}$
 - $t_{\text{meal}} = 0.5 \cdot (t_{\min} + t_2)$

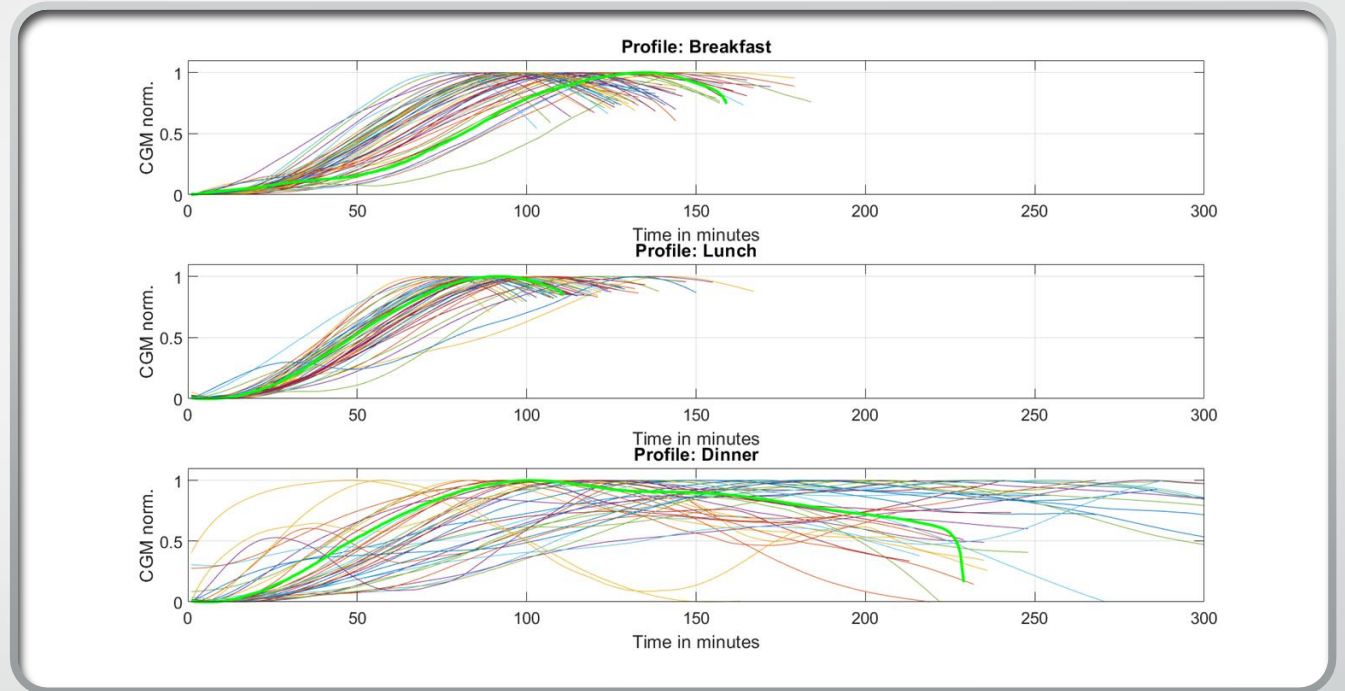
Lukas Schubert



09/23/2019

Vergleich mit anderen Ansätzen

- Pattern Matching mit DTW Ansatz:
 - Referenzprofile aus den ersten Studientagen
 - Skalierung der Profile mit DTW
 - Pattern Matching mit skalierten Profilen



Kombination der offline Algorithmen

- Best of Three System
- Erkennen mindestens 2 Algorithmen (in einem bestimmten Intervall) eine Mahlzeit, so wird diese als bestätigt angesehen.

Ergebnisse

	Model based		heuristic		DTW	
Criteria	mean	std	mean	std	mean	std
Nr. of meals	24,4	4,3	24,1	3,9	21,8	3
Nr. detected	20,3	4,3	19,1	3,9	19,1	3
ΔT [min]	16,3	5,49	19,5	4,26	34,6	6,4
TP	18,9	5,1	17,5	4,4	16,2	2,7
FN	5,49	2,8	6,59	3,3	5,57	3,4
FP	2,7	2	2,49	2,5	3,3	2,7
FP/day	0,459	0,34	0,422	0,43	0,554	0,45
Sensitivity [%]	76,9	12	72,5	13	75,2	13
F1 Score	0,813	0,09	0,789	0,11	0,787	0,12

Ergebnisse

Criteria	RICAM		Harvey		Kombination	
	mean	std	mean	std	mean	std
Nr. of meals	24,7	4,3	32,2	7,7	22,4	3,4
Nr. detected	18,7	4,3	20,9	7,7	15,5	3,4
ΔT [min]	20,8	5,53	28,5	4,33	17,3	7,08
TP	17	5,2	21,6	6,1	14,9	4,1
FN	7,7	3,1	10,6	5,8	7,43	3,7
FP	3,08	2,1	2,73	2,8	1,16	1,4
FP/day	0,523	0,36	0,463	0,48	0,197	0,23
Sensitivity [%]	68	14	67,9	18	66,8	16
F1 Score	0,746	0,11	0,76	0,1	0,767	0,12

Schätzung der Mahlzeitengröße

- Erweiterung des Kalman-Filters um eine Störgrößenschätzung
- Bestimmung der Kohlenhydratmenge aus der geschätzten Störung
- Größe als Funktion der Fläche unter dem Störungsverlauf

Optimierung der Parameter

- $J_1 = 10^7 * \left| \frac{1}{N} \sum_{i=1}^N (y_i - y_{ref,i}) \right| + \sum_{i=1}^N (y_i - y_{ref,i})^2$
- $J_2 = \sum_{i=1}^N (y_i - y_{ref,i})^2$

Ergebnis

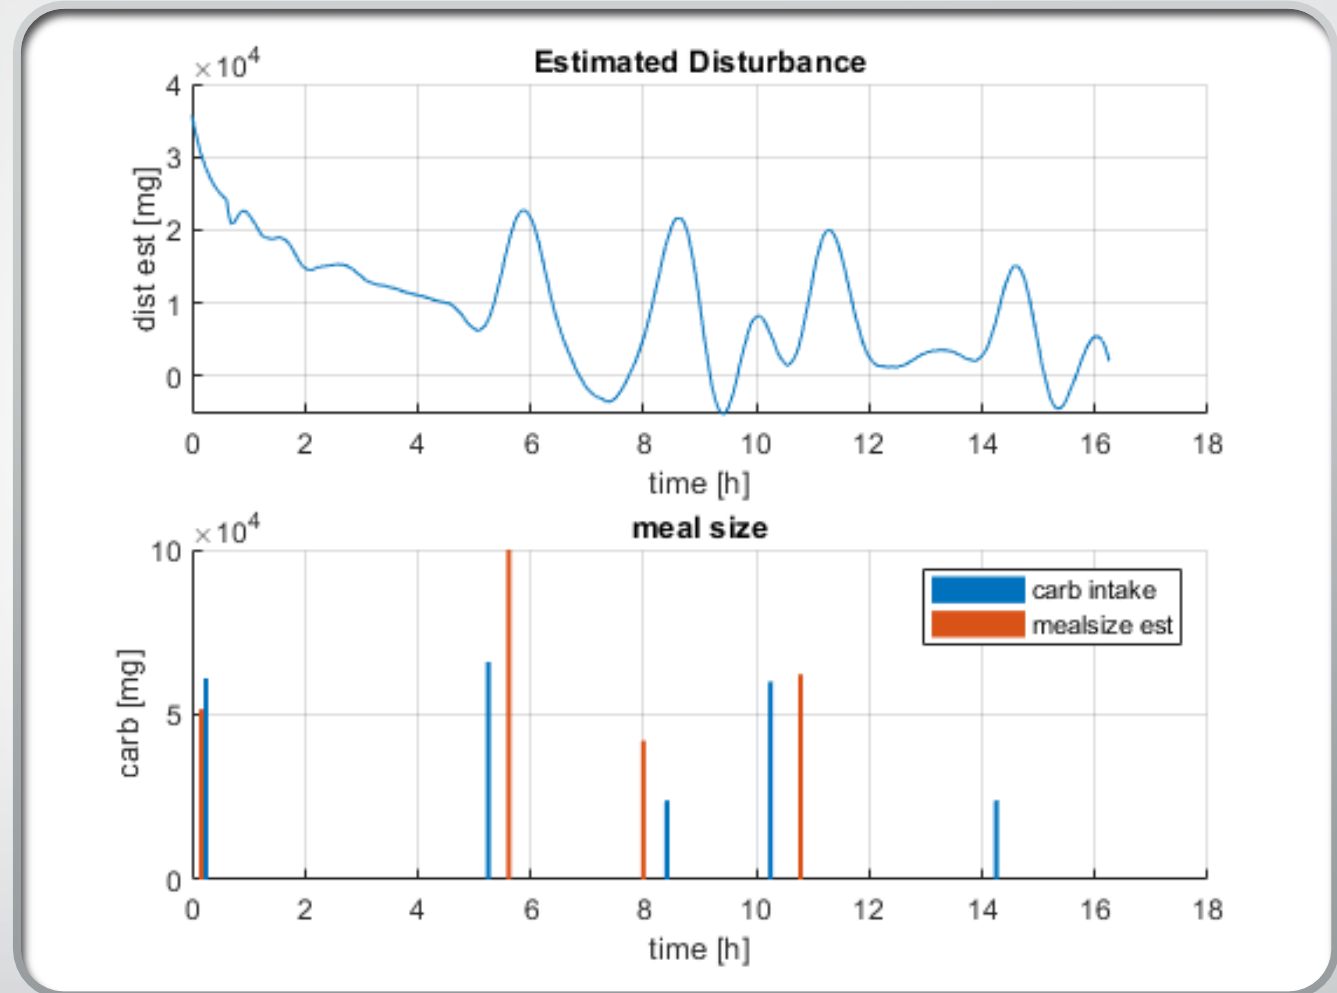
Mit Kostenfunktion J₁

Kriterium	mean	Std	Einheit
Δ meal	-0.2	+/- 32.5	g
% error	-11.6	+/- 70.5	%

Mit Kostenfunktion J₂

Kriterium	mean	Std	Einheit
Δ meal	3.4	+/- 32.6	g
% error	-5.1	+/- 64.6	%

Lukas Schubert



09/23/2019