

Innovative Datennutzung in der KAGes

Machine Learning Algorithmen im klinischen Alltag

Diether Kramer

Mit Hilfe von Machine Learning werden individuelle Prognosen bzw. Risikoprofile automatisiert erstellt

- Motivation:
 - **Frühzeitig präventive Maßnahmen setzen** bzw. Ressourcen besser einplanen zu können
 - Derzeitige Screening-Methoden können aus Ressourcengründen nicht für alle PatientInnen durchgeführt werden
- Verwendet werden nur bestehende Daten – **keine zusätzliche Erfassung von Parametern**
- Es soll eine **Unterstützung** sein, basierend auf Methoden des maschinellen Lernens (!)
- Die KAGes hat eine günstige „Datenlage“: aus ca. 2,1 Millionen „longitudinalen“ Krankengeschichten können auffällige Muster gefunden werden

Themen in Umsetzung bzw. in Vorbereitung

- Vorhersage
 - **Delir** – Hat ein neu aufgenommener Patient ein Risiko ein Delir zu entwickeln?
 - **Intensivpflichtigkeit** - Braucht ein Patient postoperativ ein Intensivbett?
 - **Dysphagie** - Hat ein neu aufgenommener Patient ein Risiko eine Dysphagie zu entwickeln?
 - **Sturz** – *Liegt eine Sturzgefährdung vor*
 - **Progression nephrologischer Erkrankungen** – *Fast vs. Slow-Progressors*
 - **Risiko kardiovaskulärer Erkrankungen** – *Primär und Sekundärprävention*
 - **Stationäre vs. Ambulante Einbestellung auf der Dermatologie**
 - *etc.*

Themen in Umsetzung bzw. in Vorbereitung

- Vorhersage
 - **Delir** – Hat ein neu aufgenommener Patient ein Risiko ein Delir zu entwickeln?
 - **Intensivpflichtigkeit** - Braucht ein Patient postoperativ ein Intensivbett?
 - **Dysphagie** - Hat ein neu aufgenommener Patient ein Risiko eine Dysphagie zu entwickeln?

Kann zu Beginn eines stationären Aufenthalt schon eine Delir-Risikoeinschätzung abgegeben werden?

etc.

Die Hintergründe der Delir-Prognose

Die Delir-Prognose wurde in einem PoC am Standort Graz-West implementiert und evaluiert

Delir..

- ..akuter Verwirrheitszustand
- ..hohe Inzidenz im Krankenhaus (bis zu ca. 30%)
- ..hohes Risiko für Komplikationen
- ..hohe Mortalität



In bis zu 40% der Fälle ist ein Delir vermeidbar!



Problem: Risiko-PatientInnen so früh wie möglich systematisch zu identifizieren!

- Variante A: Klassischer Score (z.B. DOS)
- vs.
- Variante B: Automatisierte Unterstützung durch Machine Learning Algorithmen



PixabayLicense

Die Konsequenzen eines Delirs haben (mittelfristig) direkten Einfluss auf das KAGes-Budget – wir treffen einige Annahmen auf Basis der Literatur

KAGes-Budget relevant

- Inzidenzrate von **3-29%** bei stationären Patienten
(Siddiqi et al. 2006, Pun & Ely 2007, Thomason et al. 2005)
- Verlängerung des stationären Aufenthalts **3-13 Tage**
(McCusker et al. 2003, Ely et al. 2004; Thomason et al. 2005; Witlox et al. 2010, Weinrebe et al., 2015)
- Erhöhte Arbeitsbelastung für das therapeutische Team ca. **4-22%**
(Pretto et al. 2009, Patridge et al., 2013)
- Bis zu **40%** der Delir-Fälle sind vermeidbar
(NICE 2010)

Nicht Budget relevant

- Erhöhte Mortalität (3 bis 10 fach)
(Lin et al., 2004; Pandharipande et al., 2013)
- Verminderte kognitive Rehabilitation
(Girard et al., 2010; Witlox et al., 2010)
- Häufig erschwertes oder kein Zurückkehren zu einem gewohnten Lebensstil
(MacLulich et al., 2008; Witlox et al., 2010)
- Größere Wahrscheinlichkeit für einen Pflegeheimeintritt nach einem Krankenhausaufenthalt
(Balas et al., 2009; Bickel et al., 2008)

Eine darauf basierende Budget Impact Modellrechnung für Delir würde daraus folgendes ergeben

- KAGes pro Jahr ca. **110.000 stationäre Patienten** in der Risikopopulation
- Bei einer angenommenen Inzidenz von **3%: jährlich 3000 Patienten** mit Delir
- Annahme: im Durchschnitt 7 Tage länger stationär, pro Tag € 500 und höherer Pflegebedarf ergibt **zusätzliche Kosten von 10.500.000 €**
- Eine Prognosemethode erkennt >80% der Delir-Patienten frühzeitig und 40% gelten als vermeidbar:
Kosteneinsparungspotential pro Jahr (mittelfristig): 2.152.500 €

Variante A: Eine anerkannte Skala zum Delirium Screening – drei mal täglich ausfüllen

DOS-SKALA 11

Tabelle 1: DOS-Skala (in Anlehnung an 10, Deutsche Version 8)

| BEOBACHTUNGEN Der Patient ... | Datum: | | | Datum: | | | Datum: | | | |
|--|------------|------|--------------|------------|------|--------------|------------|------|--------------|---|
| | Tag-dienst | | Nacht-dienst | Tag-dienst | | Nacht-dienst | Tag-dienst | | Nacht-dienst | |
| | ja | nein | ja | ja | nein | ja | ja | nein | ja | |
| 1. nickt während des Gesprächs ein. | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 |
| 2. wird durch Reize der Umgebung schnell abgelenkt. | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 |
| 3. bleibt aufmerksam im Gespräch oder in der Handlung. | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 |
| 4. beendet begonnene Fragen oder Antworten nicht. | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 |
| 5. gibt unpassende Antworten auf Fragen. | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 |
| 6. reagiert verlangsamt auf Aufträge. | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 |
| 7. denkt, irgendwo anders zu sein. | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 |
| 8. erkennt die Tageszeit. | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 |
| 9. erinnert sich an kürzliche Ereignisse. | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 |
| 10. nestelt, ist ruhelos, unordentlich und nachlässig. | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 |
| 11. zieht an Infusionen, an Sonden oder an Katheter usw. | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 |
| 12. reagiert unerwartet emotional. | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 |
| 13. sieht, hört und riecht Dinge, die nicht vorhanden sind. | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 | 0 | 1 |
| Gesamtpunktezahl pro Dienst (0-13) | | | | | | | | | | |
| endgültige Punktezahl: <3 kein Delir >3 wahrscheinliches Delir | | | | | | | | | | |
| Handzeichen: | | | | | | | | | | |

39 Items pro Patient pro Erhebung!

Vorauswahl: alle PatientInnen älter als 70:

In der KAGes ca. 110.000 stationäre PatientInnen pro Jahr

Variante A: Eine anerkannte Skala zum Delirium Screening – drei mal täglich ausfüllen

DOS-SKALA 11

Tabelle 1: DOS-Skala (in Anlehnung an 10, Deutsche Version 8)

| BEOBACHTUNGEN Der Patient ... | Datum: | | | Datum: | | | Datum: | | |
|---|---------|----------|------------|---------|----------|------------|---------|----------|------------|
| | Tag- | Nacht- | | Tag- | Nacht- | | Tag- | Nacht- | |
| | dienst | dienst | | dienst | dienst | | dienst | dienst | |
| | ne | manchmal | weiß nicht | ne | manchmal | weiß nicht | ne | manchmal | weiß nicht |
| | - immer | - immer | - immer | - immer | - immer | - immer | - immer | - immer | - immer |
| 1. nickt während des Gesprächs ein. | 0 | 1 | - | 0 | 1 | - | 0 | 1 | - |
| 2. wird durch Reize der Umgebung schnell abgelenkt. | 0 | 1 | - | 0 | 1 | - | 0 | 1 | - |
| 3. bleibt aufmerksam im Gespräch oder in der Handlung. | 1 | 0 | - | 1 | 0 | - | 1 | 0 | - |
| 4. beendet begonnene Fragen oder Antworten nicht. | 0 | 1 | - | 0 | 1 | - | 0 | 1 | - |
| 5. gibt unpassende Antworten auf Fragen. | 0 | 1 | - | 0 | 1 | - | 0 | 1 | - |
| 6. reagiert verlangsamt auf Aufträge. | 0 | 1 | - | 0 | 1 | - | 0 | 1 | - |
| 7. denkt, irgendwo anders zu sein. | 0 | 1 | - | 0 | 1 | - | 0 | 1 | - |
| 8. erkennt die Tageszeit. | 1 | 0 | - | 1 | 0 | - | 1 | 0 | - |
| 9. erinnert sich an kürzliche Ereignisse. | 1 | 0 | - | 1 | 0 | - | 1 | 0 | - |
| 10. nestelt, ist ruhelos, unordentlich und nachlässig. | 0 | 1 | - | 0 | 1 | - | 0 | 1 | - |
| 11. zieht an Infusionen, an Sonden oder an Katheter usw. | 0 | 1 | - | 0 | 1 | - | 0 | 1 | - |
| 12. reagiert unerwartet emotional. | 0 | 1 | - | 0 | 1 | - | 0 | 1 | - |
| 13. sieht, hört und riecht Dinge, die nicht vorhanden sind. | 0 | 1 | - | 0 | 1 | - | 0 | 1 | - |
| Gesamtpunktzahl pro Dienst (0-13) | | | | | | | | | |
| endgültige Punktzahl: <3 kein Delir >3 wahrscheinliches Delir | | | | | | | | | |
| Handzeichen: | | | | | | | | | |

39 Items pro Patient pro Erhebung!


Vorauswahl: alle PatientInnen älter als 70:
In der KAGes ca. 110.000 stationäre PatientInnen pro Jahr

Im Vergleich mit den klassischen Scores schneidet unser Machine Learning-Modell besser ab! (Newman et al. 2015)

| | Patients | C-Statistik |
|-----------------------|----------|-------------|
| Inouye et al. 1993 | 281 | 0,66 |
| Pompei et al. 1994 | 432 | 0,64 |
| O'Keefe & Lavan, 1996 | 225 | 0,75 |
| Inouye et al, 2007 | 491 | 0,75 |
| Rudolph et al, 2011 | 100 | 0,65 |
| Martinez et al, 2012 | 699 | 0,85 |
| Kobayashi et al. 2013 | 3570 | 0,82 |
| Carrasco et al, 2013 | 272 | 0,78 |
| Douglas et al, 2013 | 374 | 0,69 |

Variante B: Auf Basis vergangener Patientenbiographien werden Muster gelernt und bei „neuen“ Patienten überprüft

Schritt 1: Training eines ML-Algorithmus




| AUROC | Interpretation |
|-------------------------------|---|
| AUROC = 0.5 | keine Diskriminierung, zufällige Vorhersage |
| $0.7 \leq \text{AUROC} < 0.8$ | akzeptable Diskriminierung |
| $0.8 \leq \text{AUROC} < 0.9$ | exzellente Diskriminierung |
| AUROC ≥ 0.9 | außerordentliche Diskriminierung |

DW Hosmer, S Lemeshow, Applied Logistic Regression, 2nd Ed. Chapter 5, John Wiley and Sons, New York, NY (2000), pp. 160-164

Variante B: Auf Basis vergangener Patientenbiographien werden Muster gelernt und bei „neuen“ Patienten überprüft

Schritt 1: Training eines ML-Algorithmus




| | Reference | |
|------------|-----------|-----|
| Prediction | NO | Y |
| NO | 1145 | 163 |
| Y | 200 | 394 |

Accuracy : 0.8091
 95% CI : (0.7908, 0.8266)

Sensitivity : 0.7074
 Specificity : 0.8513

Variante B: Auf Basis vergangener Patientenbiographien werden Muster gelernt und bei „neuen“ Patienten überprüft

Schritt 1: Training eines ML-Algorithmus




| | Reference | |
|------------|-----------|-----|
| Prediction | NO | Y |
| NO | 1145 | 163 |
| Y | 200 | 394 |

Accuracy : 0.8091
 95% CI : (0.7908, 0.8266)

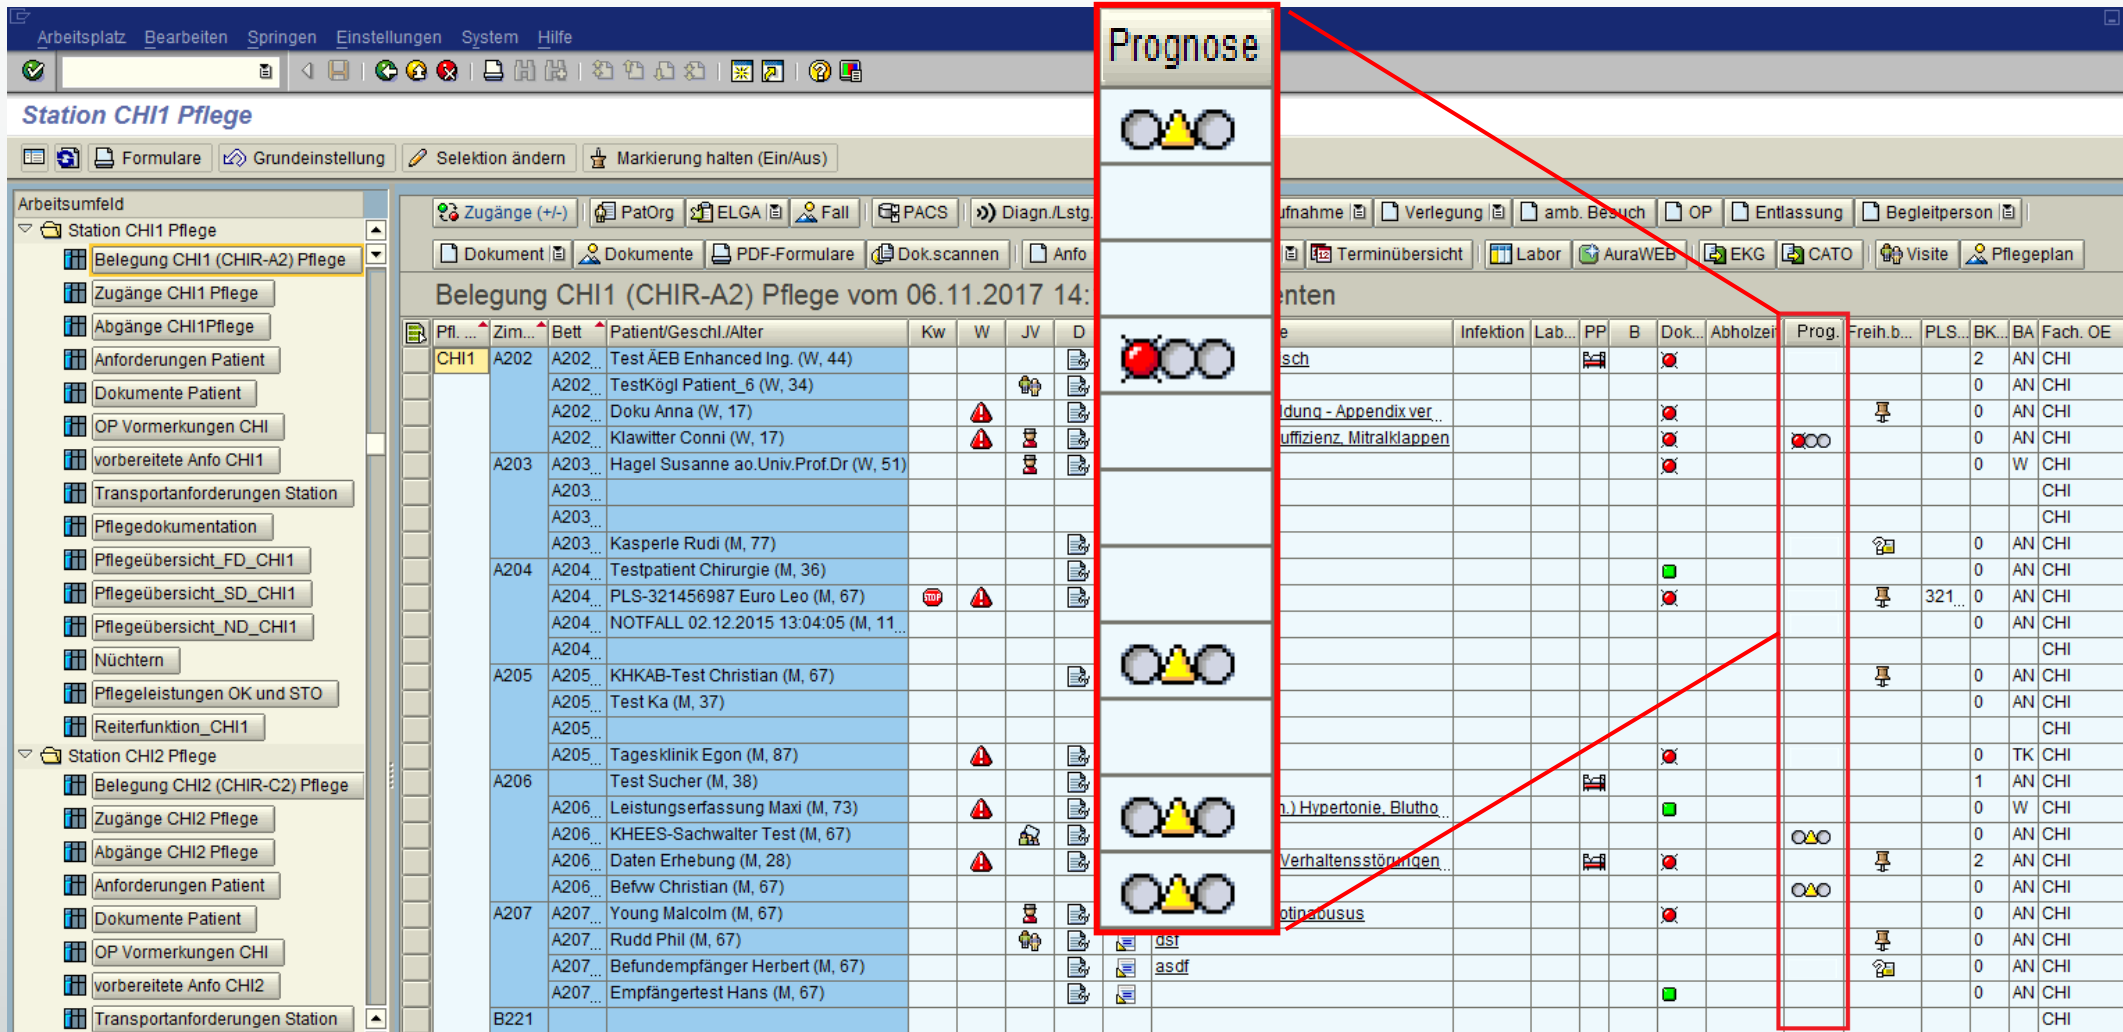
Sensitivity : 0.7074
 Specificity : 0.8513

Schritt 2: Real-time prediction



Visualisierung im Krankenhausinformationssystem

Eine Spalte wird im klinischen Arbeitsplatz integriert. Ein Ampelsystem zeigt z.B. das Delir-Risiko einzelner PatientInnen



The screenshot shows a clinical workstation interface with a patient list. A red box highlights the 'Prognose' column, which contains traffic light icons. A red line connects the 'Prognose' column header to the corresponding data cells in the table.

| Pfl. | Zim. | Bett | Patient/Geschl./Alter | Kw | W | JV | D | Prognose | Freih.b... | PLS... | BK... | BA | Fach. OE |
|------|------|------|--|----|---|----|---|----------|------------|--------|-------|----|----------|
| CHI1 | A202 | A202 | Test ÄEB Enhanced Ing. (W, 44) | | | | | | | | | | |
| | | A202 | TestKögl Patient_6 (W, 34) | | | | | | | | | | |
| | | A202 | Doku Anna (W, 17) | | | | | | | | | | |
| | | A202 | Klawitter Conni (W, 17) | | | | | | | | | | |
| | A203 | A203 | Hagel Susanne ao.Univ.Prof.Dr (W, 51) | | | | | | | | | | |
| | | A203 | | | | | | | | | | | |
| | | A203 | Kasperle Rudi (M, 77) | | | | | | | | | | |
| | A204 | A204 | Testpatient Chirurgie (M, 36) | | | | | | | | | | |
| | | A204 | PLS-321456987 Euro Leo (M, 67) | | | | | | | | | | |
| | | A204 | NOTFALL 02.12.2015 13:04:05 (M, 11...) | | | | | | | | | | |
| | | A204 | | | | | | | | | | | |
| | A205 | A205 | KHKAB-Test Christian (M, 67) | | | | | | | | | | |
| | | A205 | Test Ka (M, 37) | | | | | | | | | | |
| | | A205 | Tagesklinik Egon (M, 87) | | | | | | | | | | |
| | A206 | A206 | Test Sucher (M, 38) | | | | | | | | | | |
| | | A206 | Leistungserfassung Maxi (M, 73) | | | | | | | | | | |
| | | A206 | KHEES-Sachwalter Test (M, 67) | | | | | | | | | | |
| | | A206 | Daten Erhebung (M, 28) | | | | | | | | | | |
| | | A206 | Befw Christian (M, 67) | | | | | | | | | | |
| | A207 | A207 | Young Malcolm (M, 67) | | | | | | | | | | |
| | | A207 | Rudd Phil (M, 67) | | | | | | | | | | |
| | | A207 | Befundempfänger Herbert (M, 67) | | | | | | | | | | |
| | | A207 | Empfängertest Hans (M, 67) | | | | | | | | | | |
| | B221 | | | | | | | | | | | | |

Durch Klick auf die Ampel kann die automatisierte Einschätzung in einer Web-App geprüft werden

 **Prognose eines Delirs**


Frau
Susi Süden
(80 Jahre)

Sehr hohes Risiko



niedrig
hoch
sehr hoch

Rückmeldungen bitte an data.science@kages.at
[Zur Gebrauchsanweisung](#)
 Version 0.9

Feedback


Die Patientin wurde von der Pflege als desorientiert eingestuft!
(Stand: 09.08.2019)

Diagnosen mit Einfluss auf das statistische Modell

Zeige 5 Einträge Suche:

| Diagnosen | Datum |
|---|------------|
| Demenz bei Alzheimer-Krankheit mit spätem ... | 2018-05-10 |
| Arterielle Hypertonie | 2018-05-13 |
| Alzheimer-Krankheit mit spätem Beginn | 2018-05-30 |
| Niereninsuffizienz CKDIIIb | 2018-05-13 |
| Ulcus sacralis | 2019-08-12 |

Einträge 1 bis 5 von 5 Zurück 1 Vorwärts

Bekannte Entlassmedikation mit Einfluss auf das statistische Modell

Zeige 5 Einträge Suche:

| Medikamente | Datum |
|---------------|------------|
| TEMESTA 2,5MG | 2018-05-16 |

Einträge 1 bis 1 von 1 Zurück 1 Vorwärts

Berücksichtigte **Laborwerte** der letzten 30 Tage +



Leistungen mit Einfluss auf das statistische Modell +

Sonstige in die Berechnung eingeflossenen Faktoren +

Für den Risikoscore dieser Patientin wurden Daten von **5** Fällen berücksichtigt, davon waren **2** stationäre Aufenthalte. Die zuletzt berücksichtigten Daten sind vom **12.09.2019**.


Diese Auswertungen basieren auf in openMEDOCS vorhandenen Informationen über den Patienten

Durch Klick auf die Ampel kann die automatisierte Einschätzung in einer Web-App geprüft werden

 **Prognose eines Delirs** 

Herr
Rudi Rüssel
(80 Jahre)


Sehr hohes Risiko



niedrig hoch sehr hoch

Rückmeldungen bitte an data.science@kages.at
[Zur Gebrauchsanweisung](#)
 Version 0.9

Feedback


Bei diesem Patient wurde bereits eine Diagnose F05 Delir codiert!
(Stand: 05.09.2019)

Diagnosen mit Einfluss auf das statistische Modell

Zeige Einträge Suche:

| Diagnosen | Datum |
|---|------------|
| Delir | 2019-09-05 |
| Chronische respiratorische Insuffizienz Ty... | 2019-04-15 |
| Cholestase | 2017-03-15 |
| Benigne Hypertonie | 2019-09-02 |
| Akutes Ulcus ventriculi | 2017-03-29 |

Einträge 1 bis 5 von 41 Zurück 2 3 4 5 ... 9 Vorwärts

Bekannte Entlassmedikation mit Einfluss auf das statistische Modell

Zeige Einträge Suche:

| Medikamente | Datum |
|---|------------|
| Ciprofloxacin 500 mg | 2019-04-15 |
| Dalacin 300 mg 1-1-1 voraussichtlich bis zur Kontrolle in 1 Woche in unserer Ambulanz | 2019-07-24 |
| IV PREDNISOLON 50MG | 2016-12-09 |
| Trittico ret. 75 mg 0-0-1 | 2018-09-17 |
| Lasix 40 mg 1-0-0 unter regelm. Kontrolle der Elektrolyten | 2019-07-24 |

Einträge 1 bis 5 von 20 Zurück 2 3 4 Vorwärts

Berücksichtigte Laborwerte der letzten 30 Tage
+

Leistungen mit Einfluss auf das statistische Modell
+

Sonstige in die Berechnung eingeflossenen Faktoren
+

Für den Risikoscore dieses Patienten wurden Daten von **30** Fällen berücksichtigt, davon waren **13** stationäre Aufenthalte. Die zuletzt berücksichtigten Daten sind vom **06.09.2019**.

Diese Auswertungen basieren auf in openMEDOCS vorhandenen Informationen über den Patienten

Durch Klick auf die Ampel kann die automatisierte Einschätzung in einer Web-App geprüft werden


📄

Prognose eines Delirs

🇦🇹

Frau
Maxi Muster
(93 Jahre)

Niedriges Risiko



niedrig hoch sehr hoch

Rückmeldungen bitte an data.science@kages.at
[Zur Gebrauchsanweisung](#)
 Version 0,9

Feedback

Diagnosen mit Einfluss auf das statistische Modell -

Zeige 5 Einträge Suche:

| Diagnosen | Datum |
|---|------------|
| Arterieller Hypertonus | 2015-01-16 |
| Hypercholesterinämie | 2013-11-27 |
| Ausschluss einer Koronare Herzkrankheit | 2013-11-27 |
| Chronische NINS | 2015-01-16 |
| Diabetes mellitus Typ II | 2015-01-16 |

Einträge 1 bis 5 von 5 Zurück 1 Vorwärts

Bekannte Entlassmedikation mit Einfluss auf das statistische Modell -

Zeige 5 Einträge Suche:

| Medikamente | Datum |
|--------------------------------------|-------|
| Es wurden keine Medikamente gefunden | |

Zurück Vorwärts

Berücksichtigte Laborwerte der letzten 30 Tage +

Leistungen mit Einfluss auf das statistische Modell +

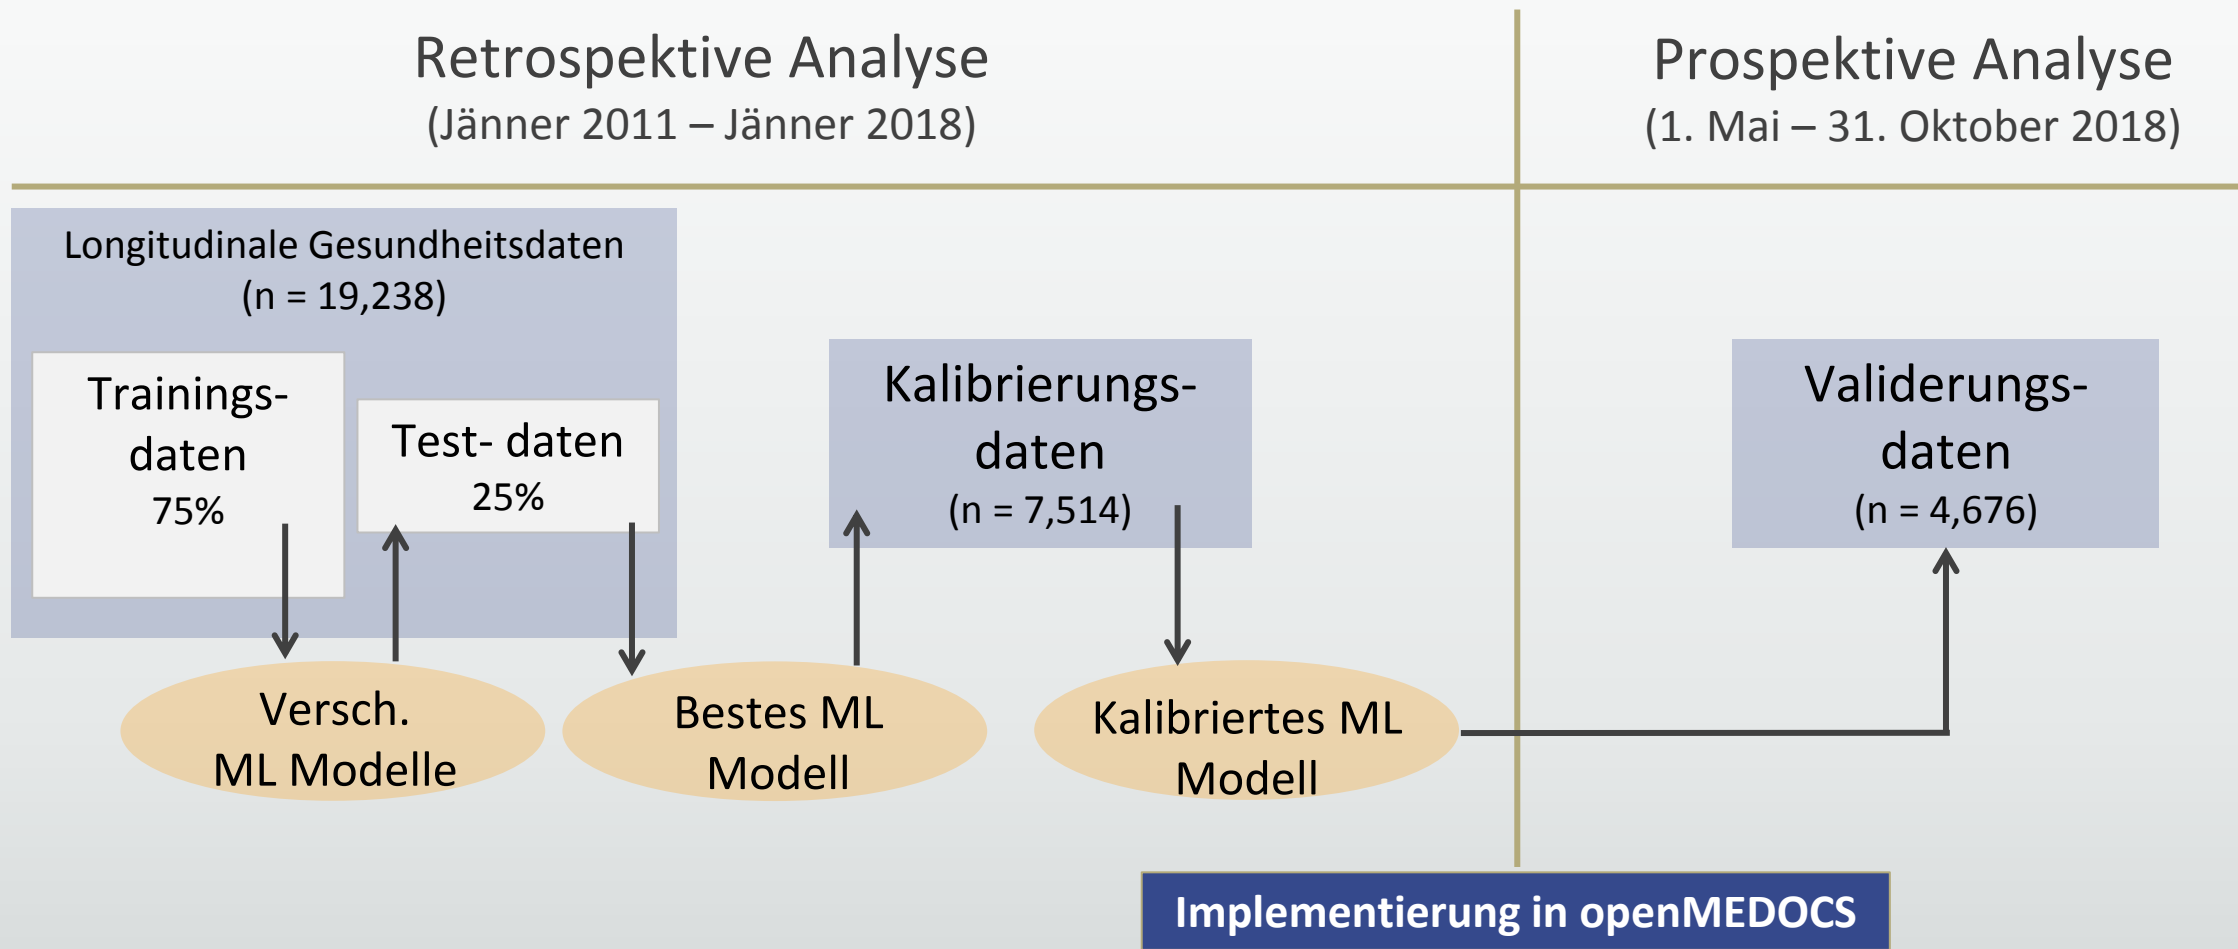
Sonstige in die Berechnung eingeflossenen Faktoren +

Für den Risikoscore dieser Patientin wurden Daten von **4** Fällen berücksichtigt, davon waren **0** stationäre Aufenthalte. Die zuletzt berücksichtigten Daten sind vom **23.08.2019**.

Diese Auswertungen basieren auf in openMEDOCS vorhandenen Informationen über den Patienten

Der Trainingsprozess

Ist das Modell im klinischen Alltag implementiert, kann es validiert werden (Hier Standort Graz-West)



Die Validierung der Ergebnisse

In der Pilotphase konnten 81.9% richtig negativ (kein Delir) und 80.2% richtig positiv (Delir) angezeigt werden

| Delirpatient | Prognose | | | Total |
|--------------|---------------|--------------|-------------|-------|
| | Blau | Gelb | Rot | |
| nein | 3728 81.9% | 514 11.3% | 308 6.8% | 4550 |
| ja | 25 19.8% | 20 15.9% | 81 64.3% | 126 |
| Total | 3753 | 534 | 389 | 4676 |

Kein Delir – d.h. nicht kein Delir-Risiko!

Hier können wir uns verbessern!

Die Algorithmen sind in der Steiermark an mittlerweile **10 Standorten** im Einsatz und zeigen sehr gute Ergebnisse

Die Evaluierung am Standort Graz-West wurde durch die teilnehmenden Stationen ermöglicht

Feedback Protokoll

Vergleich Modell und ExpertInnen

Blatt Nr. 3.
Blatt Nr. 2

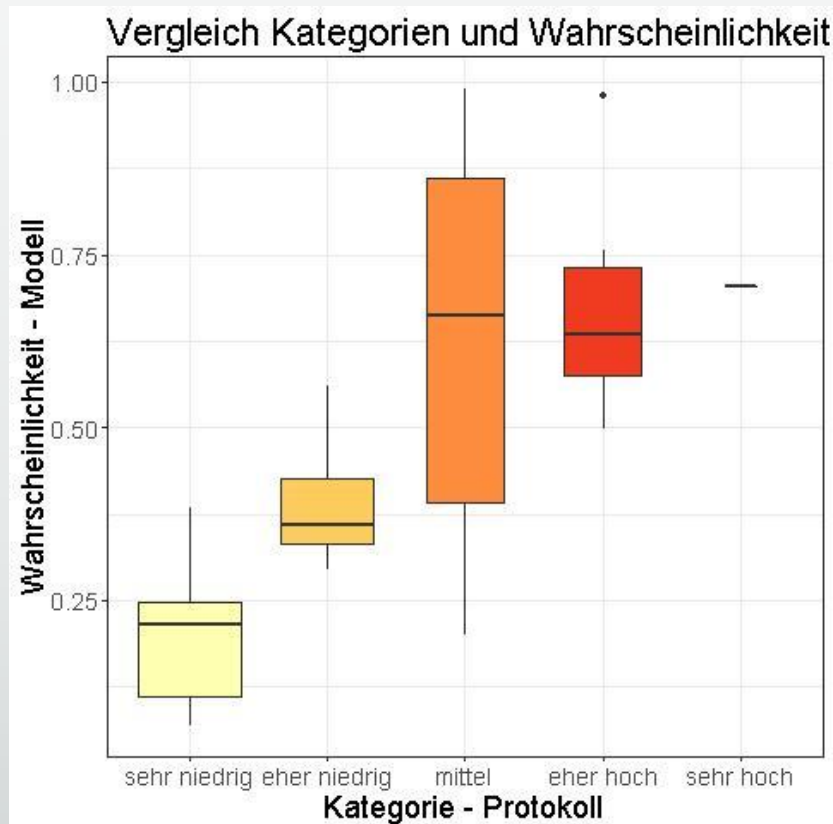
Feedback-Protokoll Delirprognose

| Nr. | Ich schätze das Risiko eines Delirs ... | | | | | Ist eine Demenz bei dem Patienten bekannt? | | Gibt es begründete Anzeichen für eine akute Veränderung des mentalen Status des Patienten? | | Fluktuiert das (veränderte) Verhalten während des Tages, d.h. hatte es die Tendenz aufzutreten und wieder zu verschwinden, oder wurde es stärker und schwächer? | | Hatte der Patient Schwierigkeiten, seine Aufmerksamkeit zu fokussieren, z.B. war er leicht ablenkbar oder hatte er Schwierigkeiten, dem Gespräch zu folgen? | | War der Gedankenablauf des Patienten desorganisiert oder zusammenhanglos, wie Gefasel oder belanglose Konversation, unklarer oder unlogischer Gedankenfluss, oder unerwartete Gedankensprünge? | | Wie würden Sie die Bewusstseinslage des Patienten allgemein beschreiben? Wach - alert (normal)? | | Kommentar | |
|-----|---|--------------|--------|-----------|-----------|--|----|--|----|---|----|---|----|--|----|---|----|-----------|-------------|
| | sehr niedrig | eher niedrig | mittel | eher hoch | sehr hoch | nein | ja | nein | ja | nein | ja | nein | ja | nein | ja | nein | ja | | |
| 8 | | | X | | | X | | | | | | | | | | | | | war bei ... |
| 8 | | X | | | | X | | X | | X | | X | | X | | | | | |
| 8 | X | | | | | X | | X | | X | | X | | X | | | | | |
| | | X | | | | X | | X | | X | | X | | X | | | | | |
| | | | | X | | X | | X | | X | | X | | X | | | | | |

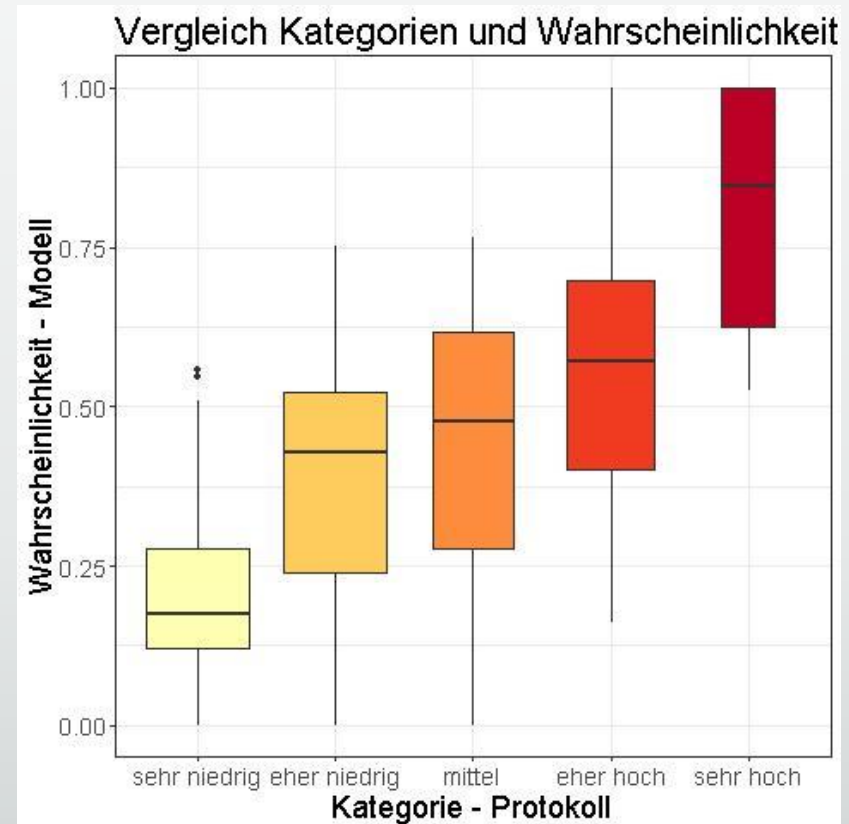
Evaluierung vor Ort

Feedback Protokoll – Die Einschätzungen von Modell und Experten stimmen in den meisten Fällen überein

- Erhebung vor Pilotphase (Frühjahr 2018, n=33)



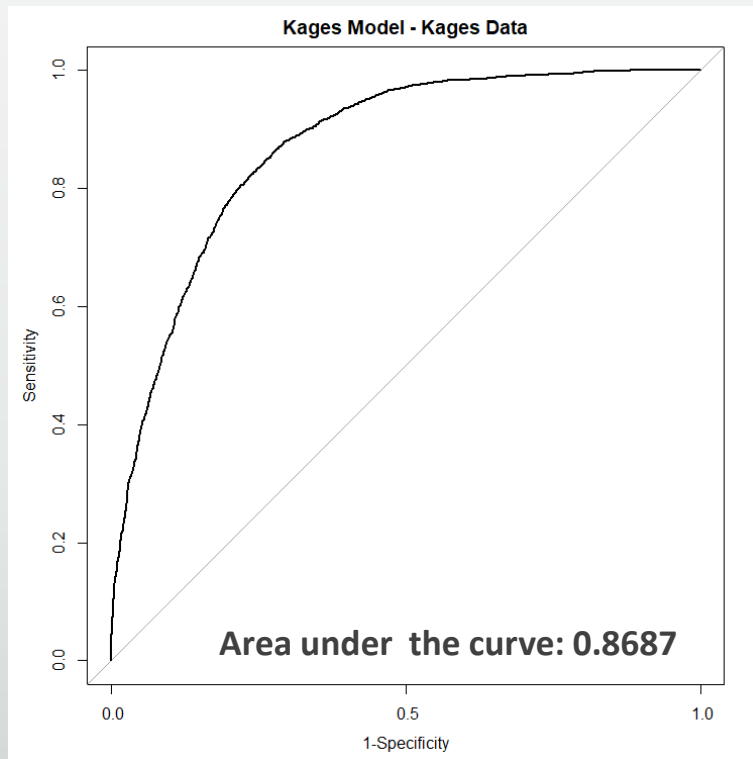
- Erhebung nach Pilotphase (Herbst 2018, n=82)



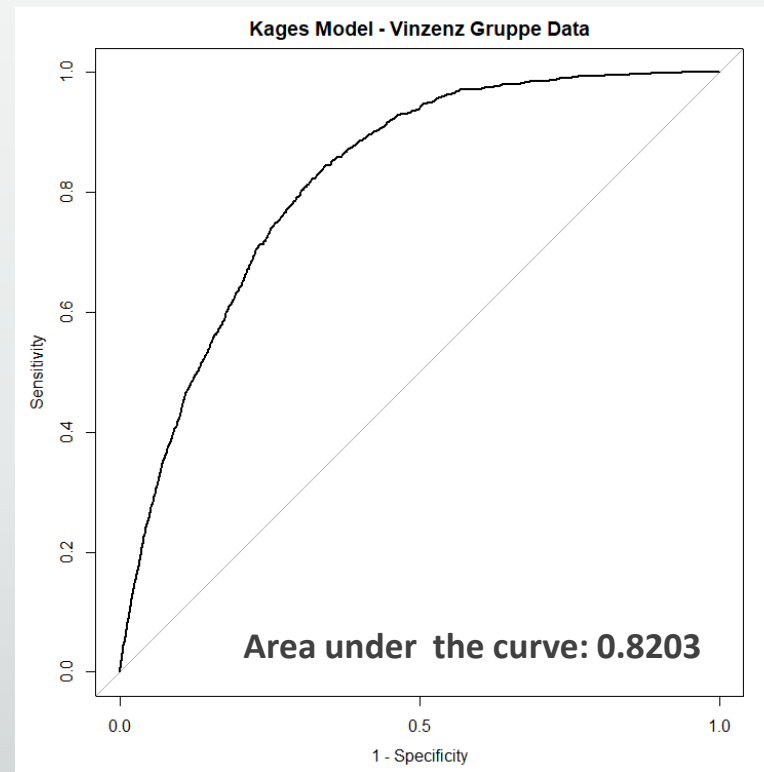
Kooperationsprojekt mit der Vinzenz Gruppe

Die Modelle funktionieren nicht nur in der KAGes: Dies zeigen uns erste Ergebnisse einer erfolgreichen Zusammenarbeit mit der Vinzenz Gruppe

Modell mit KAGes-Daten trainiert – angepasst an Daten-Verfügbarkeit



Modell mit Daten der Vinzenz Gruppe getestet



Die Kooperation ist „Work in Progress“!

Wir sind zuversichtlich die Modelle noch weiter optimieren zu können!

Wie geht es weiter?

Themen in Umsetzung bzw. in Vorbereitung

- Vorhersage
 - **Delir** – Hat ein neu aufgenommener Patient ein Risiko ein Delir zu entwickeln?
 - **Intensivpflichtigkeit** - Braucht ein Patient postoperativ ein Intensivbett?
 - **Dysphagie** - Hat ein neu aufgenommener Patient ein Risiko eine Dysphagie zu entwickeln?
 - *Sturz – Liegt eine Sturzgefährdung vor*
 - *Progression nephrologischer Erkrankungen – Fast vs. Slow-Progressors*
 - *Risiko kardiovaskulärer Erkrankungen – Primär und Sekundärprävention*
 - *Stationäre vs. Ambulante Einbestellung auf der Dermatologie*
 - *etc.*

Aufgrund vieler positiver Rückmeldungen haben wir nun begonnen, uns auch mit anderen Interessenten in Verbindung zu setzen



OXFORD UNIVERSITY PRESS | JAMIA: Journal of the American Medical Informatics Association

Risk Prediction of Delirium in Hospitalised Patients Using Machine Learning: An Implementation and Prospective Evaluation Study

| | |
|----------------|---|
| Journal: | Journal of the American Medical Informatics Association |
| Manuscript ID: | 10.1093/jamia/ocaa001 |
| Article Types: | Research and Applications |
| Keywords: | Machine learning, Prospective studies, Delirium, Electronic health records, Clinical decision support, Predictive model |

SCHOLARONE™ Manuscripts

Top 3 Journal Medical Informatics!

IN PRINT

www.predicting-health.at

Zumindest manche unserer Anwendungen sind als Software als Medizinprodukt anzusehen!

- D.h. es gilt Normen zu beachten! (13485, 14971, 62304)
- Wir werden in den nächsten Wochen die Erfordernisse für Klasse I erfüllen (Medizinprodukterichtlinie MDD 93/42/EWG)
- Wir arbeiten darüber hinaus mit Hochdruck an der Erfordernissen für Klasse IIa (Medizinprodukteverordnung MDR 2017/745)

Publikationen:

- Kramer D, Veeranki S, Hayn D, Quehenberger F, Leodolter W, Jagsch C, et al. Development and Validation of a Multivariable Prediction Model for the Occurrence of Delirium in Hospitalized Gerontopsychiatry and Internal Medicine Patients. *Studies in Health Technology and Informatics*. 2017;236:32–39.
- Hayn D, Veeranki S, Kropf M, Eggerth A, Kreiner K, Kramer D, et al. Predictive analytics for data driven decision support in health and care. *it - Information Technology*. 2018;60(4):183–194.
- Jauk S, Kramer D, Leodolter W. Cleansing and Imputation of Body Mass Index Data and Its Impact on a Machine Learning Based Prediction Model. *Studies in Health Technology and Informatics*. 2018;116–123.
- Jauk S, Kramer D, Schulz S, Leodolter W. Evaluating the Impact of Incorrect Diabetes Coding on the Performance of Multivariable Prediction Models. *Stud Health Technol Inform*. 2018;251:249–252.
- Kreuzthaler M, Pfeifer B, Vera Ramos J, Kramer D, Grogger V, Bredenfeldt S, et al. EHR Text Categorization for Enhanced Patient-Based Document Navigation. *Studies in Health Technology and Informatics*. 2018;100–107.
- Veeranki S, Hayn D, Kramer D, Jauk S, Schreier G. Effect of Nursing Assessment on Predictive Delirium Models in Hospitalised Patients. *Studies in Health Technology and Informatics*. 2018;124–131.
- Veeranki S, Hayn D, Eggerth A, Jauk S, Kramer D, Leodolter W, et al. On the Representation of Machine Learning Results for Delirium Prediction in a Hospital Information System in Routine Care. *Studies in Health Technology and Informatics*. 2018;97–100.
- Veeranki SPK, Hayn D, Jauk S, Quehenberger F, Kramer D, Leodolter W, Schreier G. An Improvised Classification Model for Predicting Delirium. *Studies in Health Technology and Informatics*. 2019;1566–7.
- Jauk S, Kramer D, Quehenberger F, Veeranki SP, Hayn D, Schreier G, Leodolter W. Information Adapted Machine Learning Models for Prediction in Clinical Workflow. *Studies in Health Technology and Informatics*. 2019;65–72.
- Jauk S, Kramer D, Stark G, Hasiba K, Leodolter W, Schulz S, Kainz J. Development of a Machine Learning Model Predicting an ICU Admission for Patients with Elective Surgery and Its Prospective Validation in Clinical Practice. *Studies in Health Technology and Informatics*. 2019;173–177.
- Lienhart A, Kramer D, Jauk S, Gugatschka M, Leodolter W, Schlegl T. Multivariable Risk Prediction of Dysphagia in Hospitalized Patients Using Machine Learning. *Studies in Health Technology and Informatics*. 2020; XXX-XXX.

Forthcoming:

- Jauk S, Kramer D, Großauer B, Rienmüller S, Avian A, Berghold A, Leodolter W, Schulz S. Real-time risk prediction of delirium in hospitalised patients using machine learning: An implementation and prospective evaluation study. *JAMIA* (forthcoming)

Vielen Dank für die Aufmerksamkeit!

diether.kramer@kages.at

diether.kramer@predicting-health.at