

## **Annotation zum Projekt „Entwicklung eines Prädiktionsmodells der Versorgung von Notfallpatienten im Raum Mittelfranken“:**

Das Projekt zielte darauf ab, auf Basis von Machine Learning Modellen eine effizientere Patientenverteilung durch den Rettungsdienst und somit eine Reduktion von Emergency department overcrowding ohne zusätzlichen Ressourceneinsatz zu erreichen.

Bedauerlicherweise wurden seitens des Zweckverbands für Rettungsdienst und Feuerwehralarmierung Nürnberg die Herausforderungen, alle Partikularinteressen der relevanten Kliniken bezüglich der Datennutzung der jeweiligen Zuweisungen zu vereinen, als zu umfangreich eingeschätzt, sodass dieses Projekt trotz vielversprechenden ersten Ergebnissen nicht weitergeführt wurde.

---

# **Entwicklung eines Prädiktionsmodells der Versorgung von Notfallpatienten im Raum Mittelfranken**

## **Hintergrund**

Im Rahmen wachsender Personalprobleme und Kapazitätsengpässe in verschiedenen Bereichen des Gesundheitswesens zeigt sich unter anderem im Bereich der Versorgung von Notfallpatienten eine zunehmende Verschärfung der Situation. Rittberg et al. konnten bereits vor Beginn der Coronapandemie am Beispiel des Großraums München einen starken Anstieg der Akutbelegungen abgemeldeter Kliniken zeigen<sup>1</sup>.

Dieser komplexen, multifaktoriellen Problemlage wird notwendigerweise auf verschiedenen Ebenen mit diversen ineinandergreifenden Maßnahmen begegnet. Eine grundsätzliche Maßnahme ist hierbei die bestmögliche, effiziente Nutzung der vorhandenen Kapazitäten, beispielsweise durch die Steuerung von Patientenzuweisungen.

Um eine bessere Beurteilung der Dynamik des Bedarfs gegenüber den vorhandenen Kapazitäten in der Notfallversorgung zu ermöglichen wurde das hier vorgestellte datenbasierte Vorhersagemodell auf Basis eines künstlichen neuronalen Netzes entwickelt.

# Modellierung

Grundlage des Prädiktionsmodells ist eine Abstraktion des Gesamtsystems, sowie die Identifizierung von messbaren Einflussfaktoren, sowohl auf die benötigten, als auch die vorhandenen Ressourcen. Hierbei richtet sich der Fokus vom gesamten System der Notfallversorgung in Mittelfranken aus zunächst auf einzelne Notaufnahmen.

Die zu versorgenden Patienten können hier klassifiziert und zwei Kategorien nach der Art ihrer Zuweisung (entweder durch den Rettungsdienst oder durch Selbsteinweisung) zugeordnet werden. Weiterhin erfordert die Versorgung jedes Patienten einen gewissen abstrakten Ressourcenbedarf. Aufgrund systemtheoretischer Überlegungen, sowie praktischer klinischer Erfahrung wird davon ausgegangen, dass der Ressourcenbedarf pro Zeiteinheit mit der Patientenzahl überproportional ansteigt (Abb. 1). Grundsätzlich kann zur Debatte gestellt werden, ob bis zu einem gewissen Punkt zunächst ein linearer Anstieg vorliegt, allerdings wird bei steigenden Patientenzahlen pro Zeiteinheit und insbesondere im relevanten Bereich der Überlastung wohl von einem überproportionalen Anstieg des Ressourcenbedarfes auszugehen sein (resultierend aus verzögerten Untersuchungen durch Ressourcenmangel, zusätzlichem organisatorischen Aufwand bei der Beschaffung von Bettenkapazitäten durch Umschichtung von Patienten, ggf. Weiterverlegung von Patienten welche wiederum das Gesamtsystem belastet, usw.). Ein dadurch entstehender Rückstau führt bei weiter bestehendem Patientenzufluss zu einer zusätzlichen Aggravation.

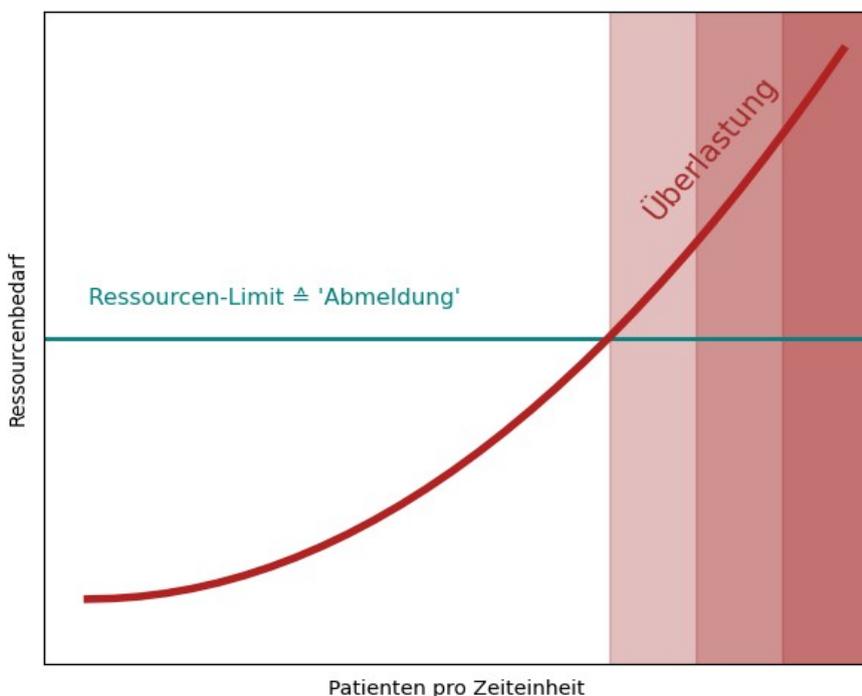


Abbildung 1: Anstieg des Ressourcenbedarfes in abhängig von der Patientenzahl (rote Kurve); der Zeitpunkt der Abmeldung von der Versorgung wird dem Schnittpunkt der Kurve des Ressourcenbedarfes (rot) mit dem Ressourcen-Limit der jeweiligen Klinik (türkis) zugeordnet.

Eine weitere zentrale Komponente ist das Angebot an Ressourcen, welches neben organisatorischen Faktoren und der Verfügbarkeit technischer Untersuchungsverfahren in erster Linie vom zur Verfügung stehenden Personal abhängig und somit zeitabhängig dynamisch ist.

Diese Faktoren müssen im Gesamtzusammenhang aller relevanten Kliniken betrachtet werden, da diese sich, insbesondere bei Abmeldung von der Versorgung bei Überlastung, gegenseitig durch Verlagerung der Patientenströme beeinflussen. Als direkte Information über die Kapazität einzelner Notaufnahmen bzw. Kliniken stand zur Modellierung lediglich der Status (abgemeldet oder angemeldet), sowie der Abmeldungszeitpunkt zur Verfügung. Darüber hinaus wurden Umweltvariablen herangezogen, bei denen ein relevanter Einfluss auf Patienten oder Personal und somit ein Informationsgewinn für die Prädiktion wurde (Abb. 2).

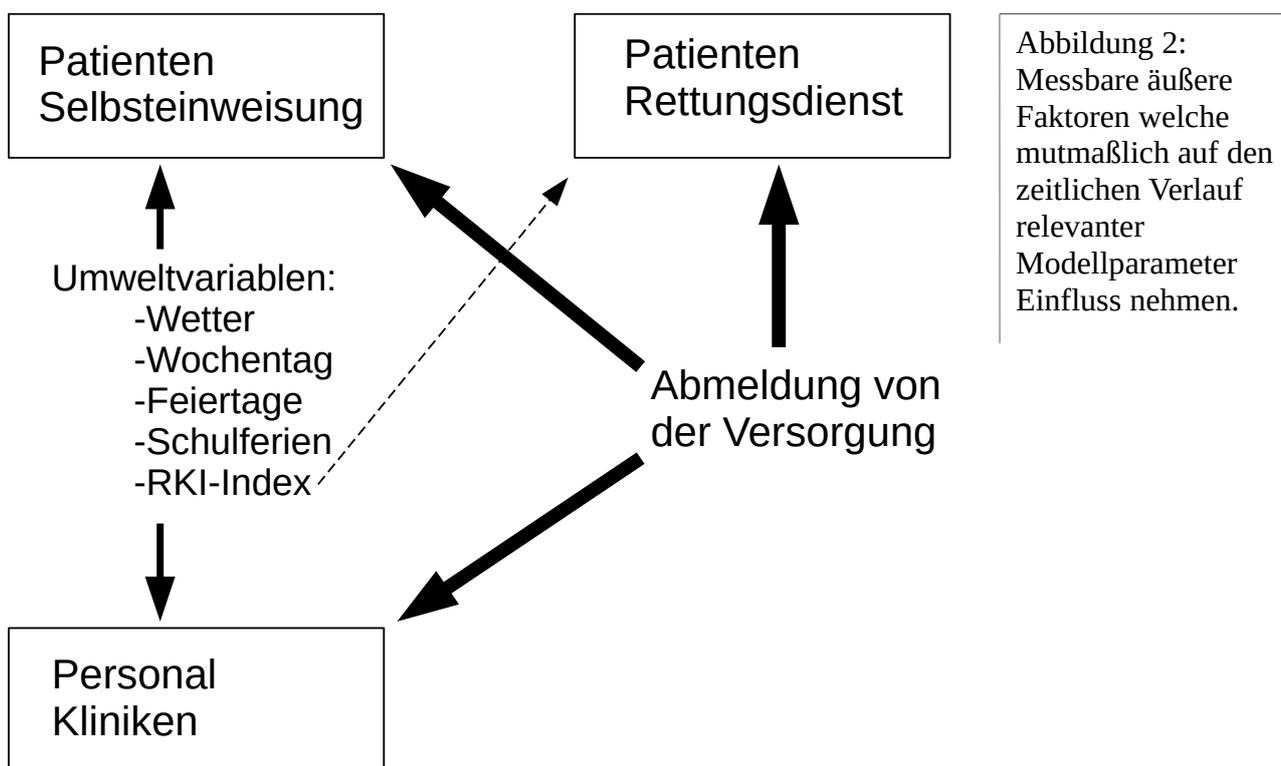


Abbildung 2:  
Messbare äußere  
Faktoren welche  
mutmaßlich auf den  
zeitlichen Verlauf  
relevanter  
Modellparameter  
Einfluss nehmen.

Ziel der folgenden Modellierung war es, das Verhalten des gesamten Systems unter Einbeziehung der genannten Hypothesen abzubilden, um eine möglichst genaue Vorhersage des zukünftigen Verhaltens zu ermöglichen. Als Grundlage wurden initial Daten aus den Zeitraum von Dezember 2018 bis Februar 2020 verwendet. Neben den Abmeldungszeitpunkten aus dem interdisziplinären Versorgungsnachweis für Mittelfranken wurden dazu auch Daten aus der Datenbank des deutschen Wetterdienstes, die von der Arbeitsgemeinschaft Influenza des RKI erhobene Konsultationsinzidenz bei akuten Atemwegserkrankungen der Vorwoche, Daten des Bayerisches Landesamt für Statistik, sowie Daten des Bayerischen Staatsministerium für Unterricht und Kultus zu Schulferienzeiten verwendet. Als Zeitraster wurde eine stundenweise Einteilung gewählt. Bei der Analyse dieser Daten konnten insbesondere die Abmeldung der Inneren Medizin sowie der

Versorgungsmöglichkeiten für potentiell isolationspflichtige Patienten als Schlüsselparameter identifiziert werden.

Im Vergleich verschiedener Modellierungsansätze zeigte sich die Verwendung rekurrenter neuronaler Netze anderen Verfahren klar überlegen. Hier konnte durch den Einsatz eines Long short-term memory Netzes (LSTM)<sup>2,3</sup> die beste Vorhersagegenauigkeit erreicht werden. Die konkrete Implementierung und das Training des LSTM erfolgten mit der TensorFlow Programmibibliothek. Dabei wurden zur Prädiktion der nächsten 12 Stunden die jeweils vorangegangenen 12 Stunden berücksichtigt und stundenweise Vorhersagen für alle erfassten Einzelkliniken durchgeführt (Abb. 3). Zudem wurde zu jedem Zeitpunkt die Quote der aktuell insgesamt zur Verfügung stehenden Kapazitäten mit einer Gewichtung der einzelnen Kliniken nach Gesamtbettenzahl berechnet.

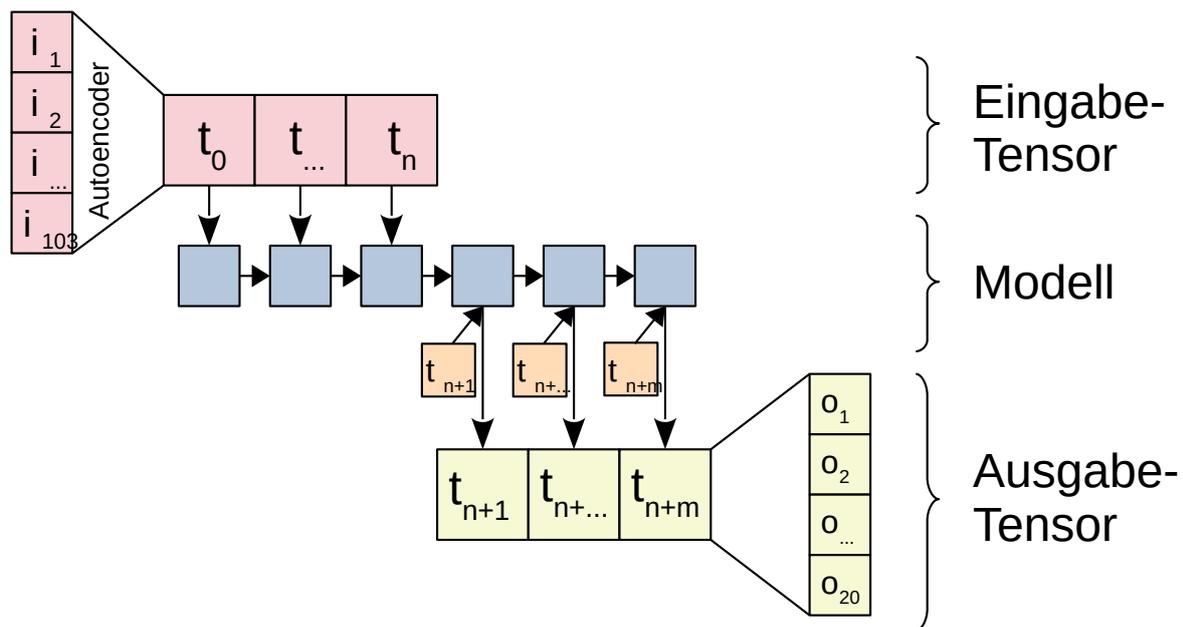


Abbildung 3: Vereinfachtes Funktionsschema des entwickelten Prädiktionsmodells.

## Performance

Bei der Validierung des Modells zeigte sich ein signifikanter Unterschied der Prädiktion des entwickelten Modells gegenüber dem Baseline-Modell (zufällige Verteilungsfunktion mit zugrunde gelegter Verteilung der Trainingsdaten,  $p < 0,01$ ). Aus dem projizierten Tensor wurden dabei die identifizierten Schlüsselfaktoren der Inneren Medizin sowie der Versorgungskapazitäten für isolationspflichtige Patienten extrahiert. Insgesamt nahm der mittlere quadratische Fehler der vorhergesagten Gesamtkapazität mit der zeitlichen Entfernung der Vorhersage von der Gegenwart zu (Abb. 4).

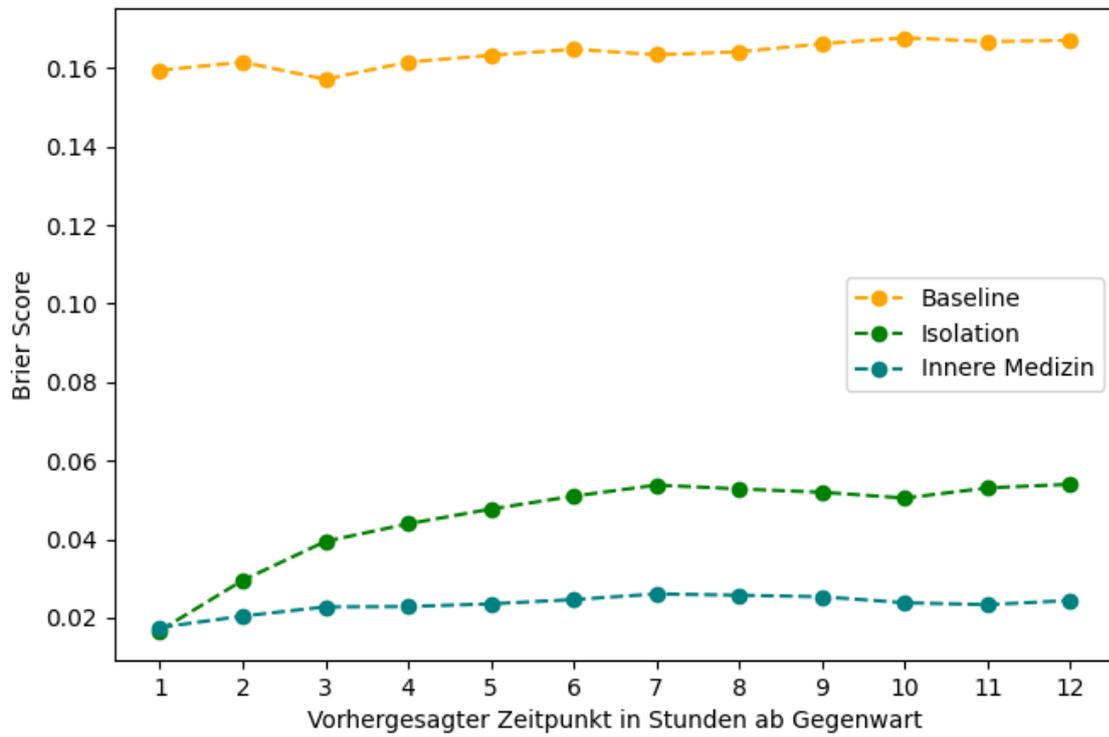
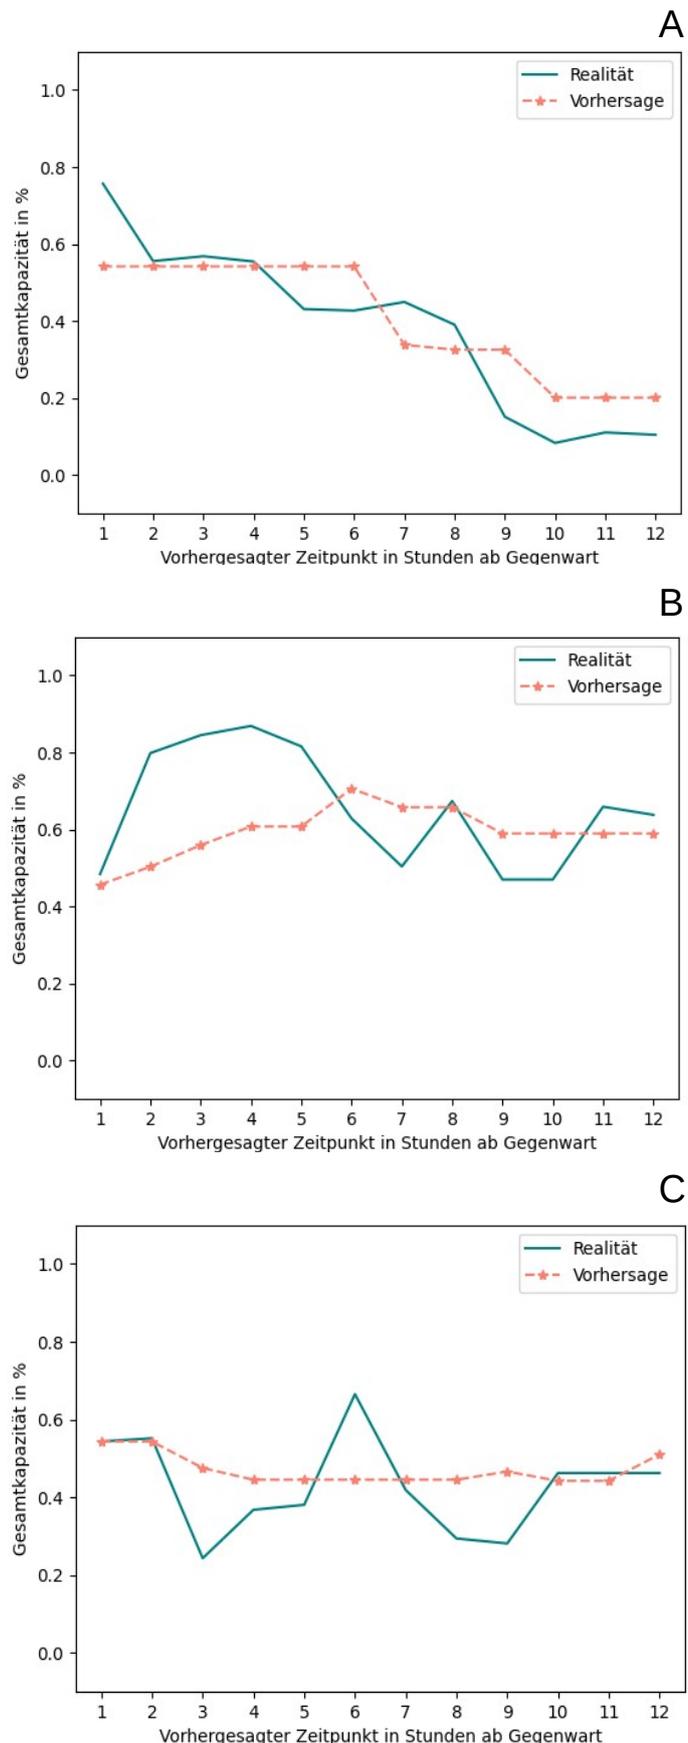


Abbildung 4: Brier-Score der Vorhersagen der Gesamtkapazität und des Baseline-Modells.

# Limitationen

Dem entwickelten Modell steht als Datenpunkt mit tatsächlichem Bezug zur Kapazität lediglich der Zeitpunkt einzelner Ab- und Anmeldungen zur Verfügung, darüber hinaus greift es zum Teil auch auf allgemeine Umweltvariablen zurück. Hierbei fehlt die Einsicht in die tatsächlich erfolgten Zuweisungen von Patienten durch den Rettungsdienst. Die resultierenden Vorhersagen bilden vor allem eine Art „Grundlast“ des Systems ab und zeigen vor allem generelle Trends zur Überlastung von Teilen des Systems. Kurzzeitige Ab- und Anmeldungen einzelner Kliniken können folglich nicht exakt vorhergesagt werden, da dem Modell in der aktuellen Form hierzu schlicht kein Daten zur Verfügung stehen, welche dies abbilden können (Abb. 5).

Abbildung 5: (A) Vorhersage vom 3. Februar 2020 ab 4:00 Uhr mit guter Abbildung der realen Kapazität; (B) 17. Januar 2022 ab 9:00 Uhr und (C) 30. Januar ab 6:00 Uhr zeigen eine grundsätzlich der realen Kapazität folgende Tendenz der Vorhersage, allerdings ohne detaillierte Abbildungen der kurzfristigen Dynamik.



# Schlussfolgerungen

Durch das hier vorgestellte Vorhersagemodell ist es unter Verwendung frei einsehbarer Daten möglich Vorhersagen über die Entwicklung von Überlastungen der Notaufnahmen in Mittelfranken in einem 12-stündigen Zeitfenster zu treffen. Hierbei handelt es sich vor allem um eine Art „Grundlast“-Vorhersage. Kurzfristige dynamische Entwicklungen, beispielsweise durch flexible Patientenzuweisung durch den Rettungsdienst bleiben im vorgestellten Modell aktuell aus Gründen der Datenverfügbarkeit noch unberücksichtigt. Hier bietet sich die interessante Möglichkeit zur Erweiterung.

## Weiterentwicklung

Durch Einbeziehung der aktuellen Zuweisungsdaten des Rettungsdienstes könnten die Vorhersagen des Modells kurzfristige Dynamiken besser erfassen und die Lastsituation detaillierter abbilden. Eine dahingehende Erweiterung des Modells wäre relativ einfach möglich. Hierzu könnten die Patientenzuweisungen durch den Rettungsdienst im jeweils relevanten Zeitraum in vektorisierter Form dem Modell zugeführt werden (Abb. 6).

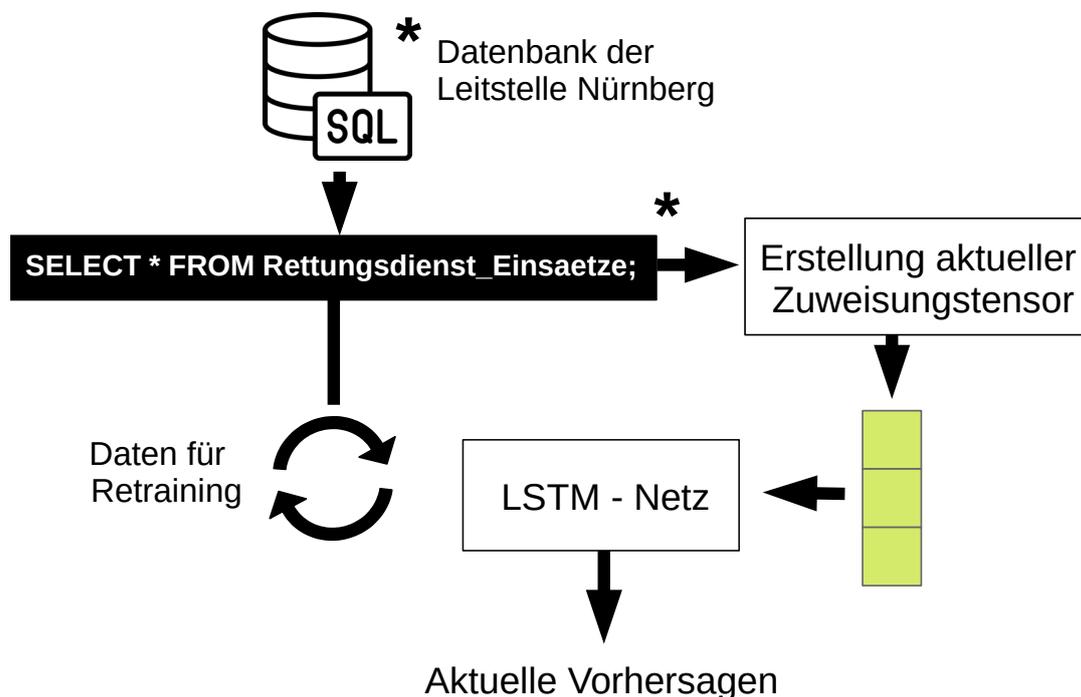


Abbildung 6: Einbeziehung von Daten aus der Datenbank der Leitstelle zur Augmentation des Vorhersagemodells; (\*) hypothetische Datenbankstruktur.

Das resultierende dynamische Vorhersagemodell böte interessante Möglichkeiten, verschiedene Anwendungen für die praktische Nutzung zu erstellen. Insbesondere wäre hier an ein System zur Optimierung der Patientenzuweisung zu denken, welches sich daraus technisch sehr einfach ableiten ließe. Durch Modellierung verschiedener Szenarien, je nach Verteilung der zukünftigen Zuweisungen durch den Rettungsdienst, wäre es möglich eine dynamische, priorisierte Empfehlungsliste zur Patientenzuweisung zur Unterstützung der Disponenten der Leitstelle zu generieren.

## Perspektive

Auf Basis des beschriebenen Modells, augmentiert mit extrapolierten, stichprobenartigen Beobachtungsdaten real erfolgter Zuweisungen durch den Rettungsdienst im Großraum Nürnberg, wurden als Proof of Concept verschiedene probabilistische Simulationen durchgeführt.

Die Ergebnisse diese Simulationen legen nahe, dass durch eine geeignete Umverteilung der Zuweisungen (Zielklinik gemäß den berechneten Empfehlungen des Modells, abweichend von der real erfolgten Zuweisung) bereits ab einer Quote von 10% bis 15% der zeitliche Anteil der Abmeldungen von Notaufnahmen um bis zu 5% reduziert werden kann.

Die Ergebnisse müssten im nächsten Schritt unter Einbeziehung der über die letzten Jahre erfassten Zuweisungsdaten der Leitstelle Nürnberg quantitativ validiert werden. Sofern diese hierdurch bestätigt würden, liegt tatsächlich der Schluss nahe, dass durch eine modellgestützte Zuweisungsstrategie eine bessere Verteilung mit gleichmäßigerer Ausnutzung der vorhandenen Ressourcen ohne personellen Mehraufwand erreicht werden kann (die aktuell durch das Bayerisches Rettungsdienstgesetz bestehenden Limitationen eines solchen Vorgehens bleiben an dieser Stelle zunächst unberücksichtigt).

- 
1. Rittberg, W. *et al.* Forced Centralized Allocation of Patients to Temporarily ‘Closed’ Emergency Departments. *Dtsch Arztebl Int* **117**, 465–471 (2020).
  2. Gers, F. A., Schmidhuber, J. & Cummins, F. Learning to forget: continual prediction with LSTM. in *1999 Ninth International Conference on Artificial Neural Networks ICANN 99. (Conf. Publ. No. 470)* vol. 2 850–855 vol.2 (1999).
  3. Yunpeng, L., Di, H., Junpeng, B. & Yong, Q. Multi-step Ahead Time Series Forecasting for Different Data Patterns Based on LSTM Recurrent Neural Network. in *2017 14th Web Information Systems and Applications Conference (WISA)* 305–310 (2017). doi:10.1109/WISA.2017.25.