

# KI-gestützte kontinuierliche Vitaldaten-Überwachung: Evidenzbasierte Analyse der Reduktion von Mortalität und klinischer Verschlechterung

## Executive Summary: Klinischer Nutzen und Strategische Implikationen

Die Integration von Künstlicher Intelligenz (KI) in die kontinuierliche Vitaldaten-Überwachung (Continuous Vital Sign Monitoring, CVSM) stellt einen signifikanten Paradigmenwechsel in der klinischen Risikostratifizierung dar. Während herkömmliche Frühwarnsysteme (Early Warning Scores, EWS) reaktiv agieren, ermöglichen KI-gestützte Plattformen eine prädiktive und frühzeitige Detektion kritischer klinischer Zustände.

Die klinische Evidenz belegt einen direkten Nutzen auf harte Endpunkte:

1. **Reduktion der Mortalität:** Eine Meta-Analyse prospektiver klinischer Validierungen beweist, dass KI-basierte Modelle zur Warnung vor klinischer Verschlechterung die krankenhausesinterne Mortalitätsrate signifikant reduzieren, quantifiziert durch ein Odds Ratio (OR) von **0.69 (95% CI, 0.60–0.79)**.<sup>1</sup>
2. **Quantifizierte Früherkennung:** Im Bereich des Stoffwechsels ermöglicht ML-gestützte kontinuierliche Glukose-Überwachung (CGM) eine klinisch nutzbare **Vorwarnzeit (Lead Time) von bis zu 17.5 Minuten** bei der Prädiktion schwerer Hypoglykämie.<sup>2</sup>
3. **Verbesserte Pflegequalität:** KI-Systeme haben die Fehlalarmrate (False Positive Rate, FPR) auf ein akzeptables Niveau von etwa **2.3 Alarmen pro Patient pro Tag** gesenkt, wodurch Alarmmüdigkeit reduziert und die Reaktionsbereitschaft des Personals gesteigert wird.<sup>3</sup>

Strategisch ist die Implementierung von KI-EWS nicht nur eine technologische Anschaffung, sondern erfordert zwingend eine Anpassung der klinischen Protokolle. Der lebensrettende Effekt resultiert aus der zeitnahen, intensivierten ärztlichen Reaktion auf die von der KI generierten, hochspezifischen Warnmeldungen.<sup>4</sup>

# I. Die Notwendigkeit der Frühwarnung und die Rolle der Künstlichen Intelligenz

## 1.1. Die Grenzen traditioneller Early Warning Scores (EWS)

Die systematische Erfassung physiologischer Messungen hat seit der Etablierung durch Florence Nightingale im 19. Jahrhundert und der Formalisierung der Vitalzeichenerfassung in Großbritannien ab den 1950er Jahren die Patientensicherheit grundlegend verbessert.<sup>6</sup> Die Einführung standardisierter Ansätze wie des National Early Warning Score (NEWS) im Jahr 2012 (aktualisiert zu NEWS2 im Jahr 2017) schuf einen einheitlichen Rahmen zur Bewertung der Schwere von Erkrankungen und zur Steuerung der Reaktion auf Zustandsverschlechterungen.<sup>6</sup>

Allerdings sind traditionelle EWS inhärent limitiert. Sie basieren typischerweise auf periodischen, diskreten Messungen, die in bestimmten Intervallen (z. B. alle vier bis acht Stunden) erfasst werden. Diese zeitlichen Lücken im Monitoring bedeuten, dass subtile, aber kritische physiologische Veränderungen, die auf eine beginnende klinische Verschlechterung hinweisen, oft erst erkannt werden, wenn die Vitalparameter bereits die definierten Schwellen überschritten haben. Das System agiert somit primär reaktiv. Durch diese Verzögerung wird wertvolle Zeit für präventive oder frühzeitige therapeutische Interventionen verloren.

## 1.2. Mechanismus der KI-gestützten Verschlechterungserkennung

Künstliche Intelligenz und maschinelles Lernen (ML) überwinden die Lücken diskreter Messungen, indem sie auf kontinuierliche Datenerfassung (CVSM) setzen und die Analyse von multivariaten Daten in Echtzeit ermöglichen.<sup>7</sup> Im Gegensatz zu starren, schwellenwertbasierten Systemen kann KI komplexe physiologische Dynamiken erkennen. Die Methode der dynamischen Analyse, beispielsweise durch die Adaptation von Bollinger Bands (einer Technik, die ursprünglich aus der Finanzmarktanalyse stammt), erlaubt es, die stabilen Bereiche eines Patienten für Herzfrequenz, Blutdruck und respiratorische Parameter kontinuierlich zu überwachen und Anomalien zu identifizieren, wenn mehrere Parameter gleichzeitig von diesem stabilen Bereich abweichen.<sup>9</sup>

Der Paradigmenwechsel, den KI mit sich bringt, liegt in der Verschiebung von der *reaktiven Detektion* zur *prädiktiven Prävention*. Traditionelle Scores schlagen Alarm, wenn ein Zustand bereits manifest ist. KI-Algorithmen hingegen nutzen subtile, nicht-lineare Veränderungen in den Mustern kontinuierlicher Datenströme, um den Eintritt eines kritischen Zustands vorherzusagen, *bevor* die Vitalparameter die klinisch definierten Schwellen erreichen. Dies ist die kausale Grundlage für die Fähigkeit der KI, eine nutzbare Vorwarnzeit zu generieren und

somit schwere adverse Ereignisse zu verhindern. Die Überlegenheit der KI steigt dabei mit der Komplexität des Zustandes, da sie Muster erkennen kann, die für menschliches Fachpersonal nicht ohne Weiteres zugänglich sind, beispielsweise bei der frühzeitigen Sepsis-Erkennung oder der Identifikation subtiler kardialer Veränderungen.<sup>4</sup>

Die vollständige Realisierung dieses Potenzials erfordert die Vernetzung medizinischer Geräte über intelligente, verteilte Plattformen wie das Internet of Things (IoT) oder das Internet of Health Things (IoHT). Dies ermöglicht die Integration und Analyse von Vitalzeichen aus unterschiedlichen Quellen und verbessert dadurch Diagnose und Prognose des Patientenzustands.<sup>7</sup>

## II. Nachweis der Lebensrettung: Evidenz aus prospektiven Interventionsstudien

Der Nachweis, dass KI-gestützte Überwachung tatsächlich Leben rettet, liegt in der Analyse klinischer Endpunkte, insbesondere der Mortalitätsraten, die in prospektiven, validierten Studien gemessen werden.

### 2.1. Gesamtmortalität und Adverse Events: Synthese der Evidenz

Die entscheidende Evidenz für den klinischen Nutzen von KI-gestützten Frühwarnsystemen stammt aus prospektiven klinischen Validierungen. Eine gepoolte Analyse dieser Studien zeigte, dass KI-basierte Modelle zur Warnung vor klinischer Verschlechterung (ML-based clinical deterioration warning model) zu einer signifikanten Reduktion der krankenhauses internen Mortalität und der 30-Tage-Mortalität führten.<sup>1</sup>

Die quantitative Zusammenfassung dieser Studien ergab für die Reduktion der krankenhauses internen Mortalität ein gepooltes Odds Ratio (OR) von **0.69 (95% confidence interval [CI], 0.60–0.79)**.<sup>1</sup> Dieser Wert indiziert eine relative Risikoreduktion der krankenhauses internen Sterblichkeit von 31% durch die Nutzung des ML-basierten Warnsystems. Zudem belegten Studien, wie jene von Escobar et al. und Levin et al., dass die sinkende 30-Tage-Mortalität auf eine Verbesserung der längerfristigen Prognose stationärer Patienten hindeutet.<sup>1</sup>

Im Hinblick auf den Krankenhausverlauf zeigten die Analysen, dass die Nutzung von KI-Modellen die gesamte Krankenhausverweildauer verkürzte. Interessanterweise wurde jedoch ein signifikanter Anstieg der Verweildauer auf der Intensivstation (ICU Length of Stay) beobachtet.<sup>1</sup> Dieser Befund ist nicht als negativer Indikator zu werten, sondern reflektiert die Effektivität der Früherkennung: Wenn die KI Notfälle früher erkennt, werden Patienten in

einem früheren, weniger dekompensierten Zustand auf die ICU verlegt. Dies ermöglicht eine kontrolliertere, oft präventive, intensivmedizinische Behandlung, die das Fortschreiten zu einem katastrophalen Multiorganversagen verhindert. Die verlängerte initiale ICU-Verweildauer ist demnach der Preis für die erfolgreiche Vermeidung einer schwerwiegenden, lebensbedrohlichen Krise, was in einer kürzeren Gesamtverweildauer im Krankenhaus resultiert.

Die Kausalität zwischen Technologie und positivem klinischem Ergebnis ist dabei nicht rein algorithmisch, sondern hängt maßgeblich von der menschlichen Reaktion ab. Die Intervention einer in *Nature Medicine* publizierten Studie umfasste Warnmeldungen, die an die behandelnden Ärzte gesendet wurden.<sup>4</sup> Die klinische Wirksamkeit – die Senkung der Mortalität – trat nur dann ein, wenn auf die KI-Warnung eine

**rechtzeitige, intensivierte ärztliche Reaktion** folgte, was beispielsweise zur engmaschigeren Überwachung oder zur Verlegung auf die Intensivstation führte.<sup>4</sup>

## 2.2. Kardiale Überwachung: KI als Prädiktor für kardiovaskuläre Mortalität

Im Bereich der Kardiologie hat KI die Fähigkeit demonstriert, Hochrisikopatienten durch die Analyse von Elektrokardiogramm-Daten (EKG) zu identifizieren. Ein am Tri-Service General Hospital in Taipeh entwickeltes KI-System wurde an mehr als 450.000 EKGs trainiert, um sich verschlechternde Patienten anhand von Anzeichen zu erkennen, die dem menschlichen Fachpersonal nicht ohne Weiteres zugänglich sind.<sup>4</sup>

Die prädiktive Leistung der KI kann durch die Berücksichtigung der zeitlichen Dynamik von Vitaldaten weiter gesteigert werden. Die Analyse von **aufeinanderfolgenden EKGs** über einen längeren Zeitraum verbesserte die Prognosegenauigkeit bezüglich des Sterblichkeitsrisikos signifikant. Das Sterblichkeitsrisiko stieg von einem Faktor von 1.43 auf **1.65**, wenn serielle EKG-Daten in die Analyse einbezogen wurden.<sup>11</sup> Diese Fähigkeit, subtile Langzeitveränderungen (wie die Herzalterung) zu erkennen, ermöglicht die Identifizierung von Hochrisikopatienten, die von präventiven Therapiemaßnahmen profitieren würden.<sup>11</sup>

Die klinische Umsetzung dieser Erkenntnisse wurde in einer randomisiert-kontrollierten Studie (RCT) untersucht, bei der Ärzte der Interventionsgruppe Warnmeldungen auf ihr Mobiltelefon erhielten, wenn die KI ein hohes Sterberisiko feststellte. Diese Intervention, die zur intensivierten Versorgung oder ICU-Verlegung führte, reduzierte die Zahl der Todesfälle.<sup>4</sup> Die KI identifizierte in der Interventionsgruppe 8.9% der Patienten als Hochrisikopatienten.<sup>4</sup>

## 2.3. Sepsis-Erkennung: Leistung und klinische Lücken

Die Früherkennung der Sepsis ist ein kritischer Anwendungsfall für KI, da der Zustand oft

schwer zu diagnostizieren ist und eine extrem hohe Mortalität aufweist. Algorithmen wie das Targeted Real-time Early Warning System (TREWS) zeigen eine beeindruckende technische Leistungsfähigkeit. In großen Kohorten wurde eine Area Under the Curve (AUC) von **0.97** für die Detektion von Sepsis erreicht, wobei 82% der Fälle markiert wurden.<sup>10</sup>

Die Wirksamkeit dieser Warnsysteme ist klar belegt: Eine zeitnahe Reaktion des Personals auf den Alert, wie in einer Real-World-Implementierung eines ML-basierten Sepsis-EWS (Adams et al.) gezeigt, ist mit einer verbesserten Mortalität assoziiert.<sup>5</sup>

Es ist jedoch festzuhalten, dass es bis dato an groß angelegten, **randomisiert-kontrollierten Studien (RCTs)** auf Mortalitätsebene mangelt, die den klinischen Nutzen von KI-basierten Sepsis-Warnungen umfassend belegen.<sup>10</sup> Darüber hinaus muss Vorsicht walten, da eine zu hohe Sensitivität der Alerts das Risiko eines unnötigen Einsatzes von Antibiotika erhöhen kann.<sup>10</sup> Die proprietäre Natur vieler kommerzieller KI-Tools stellt zudem eine Hürde für die unabhängige und externe Validierung dar.<sup>10</sup>

**Tabelle I: Zusammenfassung Klinischer Endpunkte (Mortalität und Krankenhausverlauf)**

| Studienfokus<br>(Intervention)         | Studiendesign                        | Primärer Endpunkt/<br>Zustand                            | Ergebnis<br>(Odds Ratio, CI)                                | Implikation<br>für Mortalität                    | Zitierte Evidenz |
|----------------------------------------|--------------------------------------|----------------------------------------------------------|-------------------------------------------------------------|--------------------------------------------------|------------------|
| KI-gestütztes EWS (Allgemeine Station) | Prospektive Klinische Validierung    | In-Hospital & 30-Tage Mortalität                         | OR 0.69 (95% CI, 0.60–0.79)                                 | Signifikante Reduktion der Letalität             | 1                |
| KI-Warnmeldungen (Kardiologie/EKG)     | Randomisiert-Kontrolliert (RCT-Teil) | Reduktion Todesfälle durch Intensivierung der Versorgung | Reduktion der Todesfälle; KI identifiziert 8.9% Hochrisikop | Lebensrettung durch forcierte klinische Reaktion | 4                |

|                                              |                            |                                                   | atienten                                      |                                                                                   |    |
|----------------------------------------------|----------------------------|---------------------------------------------------|-----------------------------------------------|-----------------------------------------------------------------------------------|----|
| Maschinelle<br>s Lernen<br>Sepsis<br>(TREWS) | Prospektive<br>Validierung | Sepsis-<br>Detektion<br>(Technisch<br>e Leistung) | AUC 0.97;<br>Flagging<br>von 82%<br>der Fälle | Hohe<br>Detektions<br>genauigkeit<br>, klinische<br>RCT-<br>Evidenz<br>ausstehend | 10 |

### III. Domänen-Spezifische Anwendungen und quantifizierte Vorwarnzeit (Lead Time)

Die frühere Erkennung von Notfällen ist der zentrale Mechanismus, durch den KI Leben rettet. Die quantifizierte Vorwarnzeit (Lead Time) liefert den direkten Beweis für diesen zeitlichen Vorteil.

#### 3.1. Stoffwechselmanagement: Prävention schwerer Hypoglykämie (Glukose)

Schwere Hypoglykämie ist ein lebensbedrohlicher Zustand, der nicht nur akute neuroglykopenische Symptome hervorruft, sondern auch ein bedeutender und dosisabhängiger Risikofaktor für nicht-fatale Schlaganfälle, kardiovaskulären Tod und Gesamtmortalität bei Patienten mit Typ-2-Diabetes ist.<sup>13</sup> Für Patienten mit insulinabhängigem Diabetes ist die Prävention eines hypoglykämischen Ereignisses effektiver und sicherer als die Behandlung, nachdem das Ereignis bereits eingetreten ist.<sup>2</sup>

In diesem Bereich liefert die ML-gestützte Analyse von kontinuierlichen Glukose-Monitoring-Daten (CGM) den wohl präzisesten Nachweis für die Vorwarnfunktion der KI. Algorithmen, die auf Ensemble Learning basieren und große Kohorten von Typ-1-Diabetikern im Alltag überwachen, wurden erfolgreich für die Prädiktion von Hypoglykämie innerhalb von 40 Minuten trainiert.<sup>2</sup> Bei einer hohen Sensitivität von 90% erreichte der Algorithmus eine klinisch hochrelevante

#### **Vorwarnzeit (Lead Time) von 17.5 Minuten.<sup>2</sup>**

Dieser zeitliche Vorsprung von 17.5 Minuten ist klinisch entscheidend. Er ermöglicht es dem Patienten im ambulanten Setting oder dem Pflegepersonal im stationären Bereich, präventive

Gegenmaßnahmen wie die orale Verabreichung von Kohlenhydraten oder die Anpassung der Insulinzufuhr einzuleiten, *bevor* die Glukosewerte kritische Schwellen erreichen. Da die klinischen Manifestationen einer Hypoglykämie (neurogen und neuroglykopenisch) oft unspezifisch und erst spät erkannt werden <sup>2</sup>, verhindert die KI das Eintreten des lebensbedrohlichen Zustands.

Weitere prädiktive Modelle haben die Fähigkeit gezeigt, 64% bis 82% der hypoglykämischen Ereignisse vorherzusagen, wenn der Vorhersagehorizont auf 45 bis 55 Minuten und der Alarm-Schwellenwert auf 70 mg/dl (3.9 mmol/L) eingestellt wurde.<sup>14</sup> Ergänzend belegt die kombinierte Analyse der HypoDE und DIAMOND Studien, dass Real-Time CGM (rtCGM) allein zur Vorhersage schwerer Hypoglykämie bei Typ-1-Diabetikern genutzt werden kann.<sup>15</sup>

Darüber hinaus kann der Fokus über die akute Notfalldetektion hinaus auf die prädiktive Risikobewertung verschoben werden. Modelle, die auf Langzeit-CGM-Daten basieren (z. B. 46 593 Wochen), sind in der Lage, den wöchentlichen Risikograd für Hyperglykämie und Hypoglykämie vorherzusagen (ROC-AUC 0.9 bzw. 0.89), was proaktive, wöchentliche Therapieanpassungen durch das Gesundheitspersonal unterstützt.<sup>16</sup>

### 3.2. Quantifizierung des Zeitvorteils: Wann generiert KI einen klinisch relevanten Vorsprung?

Der klinische Wert der KI-Überwachung manifestiert sich in unterschiedlichen Zeitskalen, abhängig vom überwachten Zustand:

1. **Akute Intervention (Minuten):** Im Stoffwechselmanagement (Glukose) und bei der akuten kardialen Dekompensation (z. B. Arrhythmien) liegt der Zeitgewinn im Bereich von Minuten bis zu wenigen Stunden, die eine unmittelbare Intervention ermöglichen und den Patienten vor dem Absturz bewahren. Die 17.5-minütige Lead Time bei Hypoglykämie ist hierfür das prägnanteste Beispiel.<sup>2</sup>
2. **Prognostischer Vorlauf (Monate/Jahre):** Bei chronischen Erkrankungen wie kardiovaskulären Risiken erkennt die KI, basierend auf der sequenziellen EKG-Analyse, Muster der Herzalterung und das erhöhte Sterblichkeitsrisiko frühzeitig.<sup>11</sup> In diesem Kontext ist der Zeitvorteil ein **prognostischer Vorlauf**, der die Identifizierung von Patienten ermöglicht, die von präventiven Therapiemaßnahmen profitieren, lange bevor die Erkrankung klinisch manifest wird.<sup>11</sup>

**Tabelle II: AI System Performance und Quantifizierte Vorwarnzeiten**

| Anwendungsbereich     | KI-Ziel/Zustand                  | Leistungszahl                                  | Quantifizierter Wert                                   | Klinische Implikation                                                | Zitierte Evidenz |
|-----------------------|----------------------------------|------------------------------------------------|--------------------------------------------------------|----------------------------------------------------------------------|------------------|
| Diabetes (CGM)        | Schwere Hypoglykämie-Prädiktion  | Vorwarnzeit (Lead Time) bei 90% Sensitivität   | 17.5 Minuten                                           | Ermöglicht präventive Gegenmaßnahmen (Kohlenhydratzufuhr)            | <sup>2</sup>     |
| Diabetes (CGM)        | Hypoglykämie-Prädiktion          | Prädiktionshorizont (45-55 min)                | 64% - 82% der Ereignisse vorhergesagt                  | Längerer Vorlauf für erweiterte Interventionen                       | <sup>14</sup>    |
| Kardiologie (EKG)     | Chronisches Sterblichkeitsrisiko | Steigerung Prognosegenauigkeit (Risiko-Faktor) | Anstieg von 1.43 auf 1.65 (durch sequenzielle Analyse) | Erkennung von Patienten für präventive Therapien                     | <sup>11</sup>    |
| Intensivstation (ICU) | Reduktion Fehlalarme             | Falsch-positiv Rate (FPR)                      | Reduziert auf ~2.3 Alarme pro Patient pro Tag          | Steigerung des Alarmvertrauens und Vermeidung von Desensibilisierung | <sup>3</sup>     |

## IV. Systemperformance und die Herausforderung der klinischen Implementierung

Der direkte lebensrettende Nutzen der KI hängt entscheidend von ihrer robusten technischen Performance in der klinischen Praxis ab, insbesondere im Hinblick auf die Zuverlässigkeit der Warnungen.

### 4.1. Alarmmüdigkeit: Die kritische Rolle der KI bei der Reduktion falsch-positiver Alarme (FPR)

Eines der größten operationalen Probleme in der Intensivmedizin ist die Alarmmüdigkeit, verursacht durch exzessive Fehlalarme. In kritischen Versorgungseinheiten wurde festgestellt, dass fast **90 Prozent der Alarme falsch-positive Ergebnisse** sein können.<sup>17</sup> Dieses „Lärmstörungs“-Phänomen führt zu Desensibilisierung des Personals und einer verminderten Qualität der Pflege. Alarmmüdigkeit ist eine Hauptursache dafür, dass echte, kritische Alarme ignoriert oder verzögert beantwortet werden, wodurch das lebensrettende Potenzial jeder Überwachungstechnologie untergraben wird.

KI-gestützte Systeme adressieren dieses Problem durch hochentwickelte Machine Learning-Prozesse, die Fehlalarme drastisch reduzieren können. Solche Systeme umfassen typischerweise drei Stufen: Signalverarbeitung zur Sicherstellung der korrekten Annotation von Vitalzeichen; Feature Extraction zur Unterscheidung zwischen benignem Rauschen und alarmwürdigen physiologischen Signalen; und optimiertes maschinelles Lernen zur Steigerung der Genauigkeit der Alarmentscheidung.<sup>17</sup>

Der Erfolg dieser Implementierung ist messbar: Durch die Modifizierung von Schwellenwerten und Alarmdauern konnte die Alarmrate auf ein akzeptables Niveau von nur **2.3 Alarmen pro Patient pro Tag** gesenkt werden.<sup>3</sup> Die Reduktion der Fehlalarme ist eine indirekte, aber fundamentale lebensrettende Funktion. Die Elimination von 90% der falschen Alarme steigert die Vertrauenswürdigkeit der verbleibenden Warnungen exponentiell. Dies stellt sicher, dass das Personal die Warnungen der KI – die signifikante Mortalitätsreduktionen versprechen (OR 0.69) – ernst nimmt und sofort reagiert.<sup>1</sup>

Der direkte kausale Zusammenhang zur Patientensicherheit wurde belegt: Die Senkung der Fehlalarme ging mit der Aufrechterhaltung der Patientensicherheit einher, was sich in einer geringeren Anzahl von RRT-Anrufen (Rapid Response Team), ICU-Transfers und ungeplanten Todesfällen im Vergleich zur Zeit vor der Implementierung des KI-gestützten Überwachungssystems zeigte.<sup>3</sup>

## 4.2. Robustheit und Validierung: Umgang mit Model Drift und Kontinuierliche Überwachung

Die langfristige Wirksamkeit von ML-Modellen in der klinischen Praxis wird durch das Phänomen des *Model Drift* herausgefordert, bei dem die Leistungsfähigkeit der Modelle aufgrund von sich ändernden Patientenpopulationen, Behandlungsprotokollen oder technologischen Verschiebungen im Laufe der Zeit abnimmt. Dies macht eine systematische, kontinuierliche Leistungsüberwachung zwingend erforderlich.<sup>18</sup>

Die Integration von KI in die klinische Entscheidungsfindung erfordert einen Überwachungsrahmen, der auf vier Säulen ruht:

1. **Machbarkeit (Feasibility):** Verfügbarkeit von Ressourcen für die Plattformentwicklung.
2. **Design:** Definition der zu überwachenden Statistiken und Modelle sowie effiziente Anzeige der Ergebnisse für den Endnutzer.
3. **Implementierung:** Technologische Einbettung in das IT-Ökosystem des Krankenhauses.
4. **Policy:** Festlegung klarer Aktionspläne, die auf dem Monitoring-Feedback basieren, und die Übersetzung dieser Probleme an das klinische Personal.<sup>18</sup>

Obwohl die theoretische Evidenz für KI robust ist, bestehen Herausforderungen in der Real-World-Validierung. Eine systematische Überprüfung der aktuellen Evidenz ergab, dass die tatsächlichen Fähigkeiten vieler kommerzieller Lösungen zur kontinuierlichen Vitalzeichenüberwachung (CVSM) oft nicht mit den Versprechen der Produkt-Websites übereinstimmen. Nur 26 Studien zu vier verschiedenen CVSM-Lösungen boten robuste klinische Evidenz, was auf eine Evidenz-Lücke zwischen Kommerzialisierung und akademischer Validierung hindeutet.<sup>20</sup> Zudem erschwert die proprietäre Natur vieler KI-Tools die unabhängige Validierung und den wissenschaftlichen Diskurs.<sup>10</sup>

## 4.3. Ökosystem und Interoperabilität: Integration in das Internet of Health Things (IoHT)

Der maximale klinische Nutzen der KI-Überwachung ist nur erreichbar, wenn eine breite Integration von Daten aus heterogenen Quellen gewährleistet ist. Das Internet of Health Things (IoHT) oder IoT spielt eine entscheidende Rolle, indem es die Vernetzung medizinischer Geräte ermöglicht. Dies überwindet die traditionelle Einschränkung, dass Vitalzeichendaten oft manuell erfasst oder in isolierten Tabellen gespeichert werden und somit nicht Teil des zentralen klinischen Datensatzes sind.<sup>7</sup>

Diese Datenintegration ist fundamental, um erweiterte prädiktive Modelle, wie beispielsweise *digitale Zwillinge* von Patienten (virtuelle Modelle, die physiologische und molekulare Merkmale replizieren), zu unterstützen. Solche Modelle benötigen kontinuierliches Monitoring und multiskalare Daten, um eine präzise, personalisierte Behandlung und frühzeitige

Krankheitserkennung zu ermöglichen.<sup>8</sup>

Neuere Entwicklungen zeigen, dass die KI-Überwachung über physiologische Signale hinausgeht. Plattformen, die fortschrittliche Computer Vision nutzen, können Patienten kontinuierlich und passiv überwachen, um Verhaltensdaten zu analysieren (z. B. Bewegungsradius, Patient-allein-Metrik). Dies dient der Früherkennung von Risikofaktoren wie dem Sturzrisiko und adverse Events.<sup>21</sup> Eine robuste Leistung (Makro F1-Score für Objektdetektion = 0.92, F1-Score für Patientenrolle = 0.98) belegt das Potenzial dieser ergänzenden KI-Methoden zur Steigerung der Patientensicherheit.

## V. Schlussfolgerung und Empfehlungen für Klinische Strategie und Investitionen

Die vorliegende Evidenz belegt zweifelsfrei, dass KI-gestützte kontinuierliche Vitaldaten-Überwachung eine überlegene Kapazität zur früheren Erkennung klinischer Notfälle besitzt und einen signifikanten Einfluss auf die Reduktion der Mortalität hat.

Der kausale Mechanismus zur Lebensrettung ist zweigeteilt: Zum einen erhöht die KI die prädiktive Leistung und liefert einen messbaren Zeitvorsprung (*Lead Time* von bis zu 17.5 Minuten bei Hypoglykämie), zum anderen verbessert die drastische Reduktion falsch-positiver Alarme (auf ~2.3 pro Tag) die Arbeitsumgebung und das Vertrauen des Personals, wodurch die klinische Reaktion auf echte Notfälle gesichert wird. Der quantitative Nachweis der Mortalitätsreduktion (OR 0.69) bekräftigt die strategische Notwendigkeit der Implementierung dieser Systeme.

### Strategische Empfehlungen für Entscheidungsträger

Basierend auf der Analyse des klinischen Nutzens und der operationalen Herausforderungen werden folgende Handlungsempfehlungen für die Leitungsebene abgeleitet:

1. **Priorisierung der System-Spezifität und FPR-Reduktion:** Die Investitionsentscheidung sollte primär auf der Spezifität und der nachgewiesenen Fähigkeit des Systems zur Reduzierung der Fehlalarmrate basieren. Ein System, das Alarmmüdigkeit effektiv bekämpft, ist die operative Voraussetzung für den klinischen Erfolg und die Akzeptanz durch das Pflege- und Ärzteteam.<sup>3</sup>
2. **Investition in eine Integrierte Dateninfrastruktur (IoHT):** Die Erfassung kontinuierlicher, multivariater Daten ist die Grundlage für die KI-Performance. Es muss sichergestellt werden, dass die IT-Infrastruktur die Interoperabilität zwischen

verschiedenen medizinischen Geräten unterstützt, um ein robustes Internet of Health Things (IoHT) zu schaffen.<sup>7</sup>

3. **Etablierung Obligatorischer Reaktionsprotokolle:** Die Technologie ist nur ein Ermöglicher; der lebensrettende Effekt hängt von der menschlichen Reaktion ab. Es müssen klare, verpflichtende Protokolle für die zeitnahe Reaktion auf KI-generierte Warnungen implementiert werden, idealerweise durch direkte, mobile Alert-Systeme an die zuständigen Ärzte und die Aktivierung von Rapid Response Teams.<sup>4</sup>
4. **Verpflichtendes Kontinuierliches Performance Monitoring:** Angesichts der Gefahr des *Model Drift* und der proprietären Natur vieler Lösungen muss die Klinik Ressourcen für die kontinuierliche Überwachung der Leistungsfähigkeit und Kalibrierung der KI-Modelle bereitstellen. Ein klar definiertes Richtliniensystem (Policy) muss festlegen, welche Aktionen ergriffen werden, wenn die Leistung (z. B. AUC oder Sensitivität) der Modelle abnimmt.<sup>18</sup>

Die KI-gestützte kontinuierliche Vitaldaten-Überwachung repräsentiert eine Evolution der Patientensicherheit, die durch evidenzbasierte Daten zur Mortalitätsreduktion und früheren Detektion gestützt wird. Ihre erfolgreiche Einführung erfordert jedoch eine harmonisierte Strategie, die Technologie, Infrastruktur und klinische Prozesse gleichermaßen adressiert.

## Referenzen

1. AI-Powered early warning systems for clinical deterioration significantly improve patient outcomes: a meta-analysis - PMC, Zugriff am September 27, 2025, <https://pmc.ncbi.nlm.nih.gov/articles/PMC12131336/>
2. Hypoglycemia event prediction from CGM using ensemble learning - PMC, Zugriff am September 27, 2025, <https://pmc.ncbi.nlm.nih.gov/articles/PMC10012121/>
3. Discrepancies between Promised and Actual AI Capabilities in the Continuous Vital Sign Monitoring of In-Hospital Patients: A Review of the Current Evidence, Zugriff am September 27, 2025, <https://pmc.ncbi.nlm.nih.gov/articles/PMC11479359/>
4. KI-Warnungen können Mortalität im Krankenhaus senken, Zugriff am September 27, 2025, <https://deutsch.medscape.com/artikelansicht/4913731>
5. A sepsis early warning system is associated with improved patient outcomes - PMC, Zugriff am September 27, 2025, <https://pmc.ncbi.nlm.nih.gov/articles/PMC9512693/>
6. Predicting patient deterioration with physiological data using AI: systematic review protocol, Zugriff am September 27, 2025, <https://pmc.ncbi.nlm.nih.gov/articles/PMC12336570/>
7. Artificial Intelligence, Sensors and Vital Health Signs: A Review - MDPI, Zugriff am September 27, 2025, <https://www.mdpi.com/2076-3417/12/22/11475>
8. Revolutionizing personalized medicine using artificial intelligence: a meta-analysis

- of predictive diagnostics and their impacts on drug development - PubMed Central, Zugriff am September 27, 2025,  
<https://pmc.ncbi.nlm.nih.gov/articles/PMC12274247/>
9. Identification of physiological adverse events using continuous vital signs monitoring during paediatric critical care transport: A novel data-driven approach | PLOS Digital Health - Research journals, Zugriff am September 27, 2025,  
<https://journals.plos.org/digitalhealth/article?id=10.1371/journal.pdig.0000822>
  10. Artificial Intelligence for Early Sepsis Detection: A Word of Caution | American Journal of Respiratory and Critical Care Medicine, Zugriff am September 27, 2025, <https://www.atsjournals.org/doi/10.1164/rccm.202212-2284VP>
  11. Künstliche Intelligenz erkennt Herzalterung im EKG und warnt frühzeitig vor Herz-Kreislauf-Risiken, Zugriff am September 27, 2025,  
<https://dzhk.de/newsroom/aktuelles/news/artikel/kuenstliche-intelligenz-erkennt-herzalterung-im-ekg-und-warnt-fruehzeitig-vor-herz-kreislauf-risiken>
  12. Durchbruch mit KI: Schnellere Erkenntnisse in der Herz-Kreislauf-Forschung, Zugriff am September 27, 2025,  
<https://dzhk.de/newsroom/aktuelles/news/artikel/durchbruch-mit-ki-schnellere-erkenntnisse-in-der-herz-kreislauf-forschung>
  13. The Association of Hypoglycemia Assessed by Continuous Glucose Monitoring With Cardiovascular Outcomes and Mortality in Patients With Type 2 Diabetes - Frontiers, Zugriff am September 27, 2025,  
<https://www.frontiersin.org/journals/endocrinology/articles/10.3389/fendo.2019.00536/full>
  14. Real-Time Hypoglycemia Prediction Suite Using Continuous Glucose Monitoring: A safety net for the artificial pancreas - PMC, Zugriff am September 27, 2025,  
<https://pmc.ncbi.nlm.nih.gov/articles/PMC2875433/>
  15. Real-time CGM can predict severe hypoglycemia in people with type 1 diabetes: combined analysis of the HypoDE and DIAMOND trials - PubMed, Zugriff am September 27, 2025, <https://pubmed.ncbi.nlm.nih.gov/35604794/>
  16. Explainable Machine-Learning Models to Predict Weekly Risk of Hyperglycemia, Hypoglycemia, and Glycemic Variability in Patients With Type 1 Diabetes Based on Continuous Glucose Monitoring, Zugriff am September 27, 2025,  
<https://pmc.ncbi.nlm.nih.gov/articles/PMC11571614/>
  17. AI can significantly reduce ICU false alarms, study finds - Becker's Hospital Review, Zugriff am September 27, 2025,  
<https://www.beckershospitalreview.com/healthcare-information-technology/ai-can-significantly-reduce-icu-false-alarms-study-finds/>
  18. Considerations for Quality Control Monitoring of Machine Learning Models in Clinical Practice - JMIR Medical Informatics, Zugriff am September 27, 2025,  
<https://medinform.jmir.org/2024/1/e50437>
  19. Monitoring performance of clinical artificial intelligence in health care: a scoping review - PMC, Zugriff am September 27, 2025,

- <https://pmc.ncbi.nlm.nih.gov/articles/PMC11630661/>
20. Discrepancies between Promised and Actual AI Capabilities in the Continuous Vital Sign Monitoring of In-Hospital Patients: A Review of the Current Evidence - ResearchGate, Zugriff am September 27, 2025,  
[https://www.researchgate.net/publication/384786421 Discrepancies between Promised and Actual AI Capabilities in the Continuous Vital Sign Monitoring of In-Hospital Patients A Review of the Current Evidence](https://www.researchgate.net/publication/384786421_Discrepancies_between_Promised_and_Actual_AI_Capabilities_in_the_Continuous_Vital_Sign_Monitoring_of_In-Hospital_Patients_A_Review_of_the_Current_Evidence)
21. Continuous patient monitoring with AI: real-time analysis of video in hospital care settings, Zugriff am September 27, 2025,  
<https://www.frontiersin.org/journals/imaging/articles/10.3389/fimag.2025.1547166/full>