



Testraum Sprint am
Nest-Demonstrator.

Luftlesen verrät Präsenz

Sensorik | Informationen über die Raumbelegung respektive die Präsenz sind wertvoll, um die Energieeffizienz, den Raumkomfort, die Raumluftqualität, die Funktionalität, die Sicherheit und schliesslich die Wirtschaftlichkeit von Gebäuden zu verbessern. Dabei gibt es einerseits verschiedene Kategorien der Präsenzschätzung und andererseits unterschiedliche Sensoren zu ihrer Ermittlung.

MICHAEL LOCHER, ERFAN HAGHIGHI

Die Präsenzschätzung ist ein nützliches Hilfsmittel, um die Energieeffizienz, den Raumkomfort, die Raumluftqualität und weitere Aspekte eines Gebäudes zu verbessern. Es gibt verschiedene Kategorien der Präsenzschätzung:

- Präsenz: Anwesenheit von Personen
- Präsenzzählung: Anzahl Personen
- Präsenzlokalisierung: Positionen anwesender Personen
- Präsenzidentität: Identität anwesender Personen

Dieser Beitrag befasst sich hauptsächlich mit den ersten zwei Punkten, denn sie sind für Effizienz- und Komfortsteigerungen am relevantesten.

Zur automatischen Erfassung der Präsenz werden typischerweise Bewegungsmelder oder Präsenzmelder benutzt, am häufigsten passive Infrarotsensoren (PIR). Zum Einsatz kommen auch optische Sensoren für die Präsenzschätzung. Neben diesen direkten Messmethoden kann eine Präsenzschätzung auch indirekt durchgeführt werden, beispielsweise über Daten von Stromzählern, WLAN-Nutzungsdaten oder Raumtemperatur- und Raumluftqualitätssensoren wie CO₂-Sensoren. Solche Sensoren können unterschiedliche Präsenzinformationen messen und haben ihre spezifischen Vorteile und Einschränkungen (**Tabelle 1**).

Eine komplizierte Beziehung

Eine interessante, kosteneffiziente und nicht intrusive Möglichkeit zur Inferenz der Präsenz und Präsenzzählung bildet die Auswertung der Raumlufttemperatur und -qualität, insbesondere der CO₂-Konzentration. Sie erlauben Rückschlüsse auf die Präsenz und Präsenzzählung. Steigt beispielsweise die Anzahl der Anwesenden, so nimmt in der Regel die CO₂-Konzentration zu. Der exakte Zusammenhang zwischen Präsenz, Anzahl anwesender Personen und CO₂-Konzentration ist nicht trivial, sondern hochgradig nichtlinear und von vielen Faktoren abhängig.

Es gibt mathematische Ansätze, z.B. basierend auf der physikalischen Massenbilanzgleichung, die Rückschlüsse auf Präsenz und Anzahl Anwesender zulassen. Dieses physikalische Modell funktioniert für spezifisch modellierte Räume, die den initialen Annahmen entsprechen und bei denen die Modellparameter anhand ausreichender Daten genügend gut geschätzt werden können, beispielsweise ein geschlossener Raum mit den CO₂-Quellen und CO₂-Senken im Gleichgewicht. Dynamische Räume, also Räume, deren Zustand sich verändert, beispielsweise durch offene Türen, Fenster, wechselnde Aktivitäten oder interagierende Anwesende, führen zu komplexen und oft unbekannt Variablen. Sie lassen sich somit mathematisch nur schwer oder überhaupt nicht beschreiben.

Beziehungsanalyse mittels Machine Learning

Zur Identifizierung komplexer und unbekannter Variablen wird oft auf Ansätze des Machine Learning, ML, zurückgegriffen. ML zeichnet sich dadurch aus, dass es anhand vorgegebener Lernalgorithmen und Daten Modelle generieren kann, die Zusammenhänge und Wechselwirkungen identifiziert, die ansonsten nur schwer zugänglich wären. ML leidet unter mangelnder Verallgemeinerung, was im konkreten Fall bedeutet, dass ein auf einen bestimmten Raum und dessen Sensorik angepasstes ML-Modell nicht auf andere Räume, die andere Charakteristiken und Sensorik aufweisen, übertragen werden kann. Die Probleme der reinen physikalischen Formulierung und des ML-Modelles lassen sich reduzieren, indem sie zu einem hybriden Modell kombiniert werden, z. B. mittels eines Stacking-Ansatzes [3]. Dieser Ansatz geht davon aus, dass sich gewisse Situationen besser durch ein physikalisches Modell beschreiben lassen und andere durch ein ML-Modell, wobei das hybride Modell durch die weiteren Daten diese Situationen lernt und entsprechend gewichtet. Der Ansatz ist interessant, da die Implementierung nur unwesentlich aufwendiger ist als die des reinen ML-Modells. Beim ML-Modell und dem hybriden Modell kommt der XGBoost-Algorithmus zum Einsatz [1]. Die Modelle werden mittels Recall und F1-Score resp. R₂, MAE und RMSE evaluiert (**Bild 1**).

Sensortyp	Messung	Vor- und Nachteile
Passive Infrarot-Sensoren (PIR)	Infrarotlicht von Objekten innerhalb des Sichtfeldes	Vorteile: Nicht-intrusiv, Preis rund 50 CHF Nachteile: Beschränktes Sichtfeld, Präsenzdetection
Optische Sensoren	Aufnahmen der Umgebung und Bildanalyse zum Erkennen und Unterscheiden von Objekten	Vorteile: Präsenzdetection, -zählung, -lokalisierung, -identität Nachteile: Intrusiv, sensitive Konfiguration, anfällig auf Lichtverhältnisse, Sichtfeld, Preis rund 1000 CHF inkl. Funktionalität zur Erfassung von Personen
Umgebungssensoren	Raumtemperatur und Raumluftqualität	Vorteile: Nicht-intrusiv, Preis rund 50 CHF, einfache Installation Nachteile: Inferenz der Präsenzzählung nicht trivial, fehleranfällig

Tabelle 1 Übersicht über Sensortypen zur Erfassung der Präsenz.

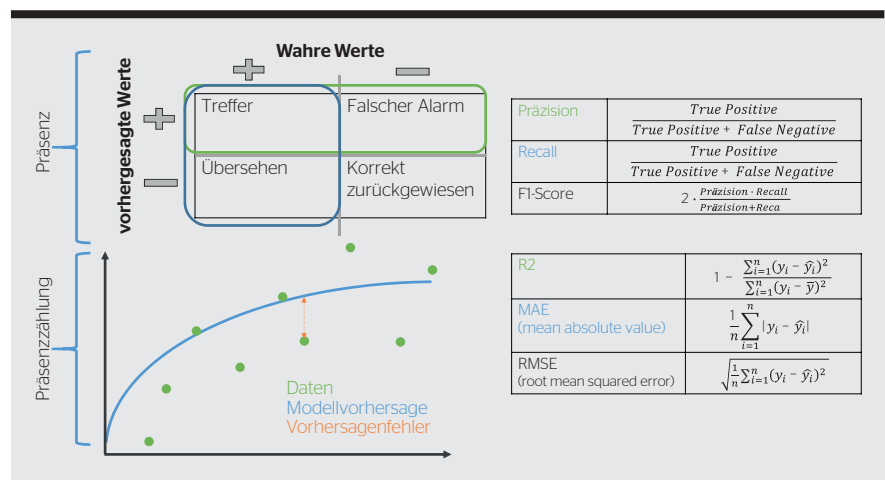


Bild 1 Übersicht der Performanzmetriken für die Erfassung der Genauigkeit der Präsenz: Präzision, Recall und F1-Score resp. Präsenzzählung R₂, MAE und RMSE.




Bild 2 Übersicht über die geprüften Feldobjekte zur Bestimmung der Präsenz.

a) Co-Working Space (128 m²), **b)** Sitzungszimmer (43 m²) und **c)** Privatbüro (10 m²). Alle Räumlichkeiten waren mit CO₂-, Beleuchtungs-, Temperatur-, Luftfeuchtigkeits- und Präsenzsensoren (PIR, optisch) ausgestattet.

Das Ziel der vorliegenden Untersuchung, an der sich als Forschungspartner Oxygen at Work beteiligte, ist es, eine theoretische Vorstellung davon zu bekommen, wie gut sich mit Informationen zur CO₂-Konzentration auf die Präsenz- und Präsenzzählung mit den drei Modellen schliessen lässt und ob sie sich für Anwendungsfälle zur Bestimmung der Präsenz in der Praxis eignen. Dazu werden folgende Kriterien

definiert: Die Genauigkeit zur Evaluation von Präsenz und Präsenzzählung sowie der Implementierungsaufwand, der sich aus der Adaptierbarkeit und dem initialen Erstellungsaufwand für einen neuen Raum ergibt. Die Datensätze dreier Räume des Nest, dem modularen Forschungs- und Innovationsgebäude der Empa und der Eawag (**Bild 2**), vom Zeitraum Juli bis Oktober 2022 werden genutzt.

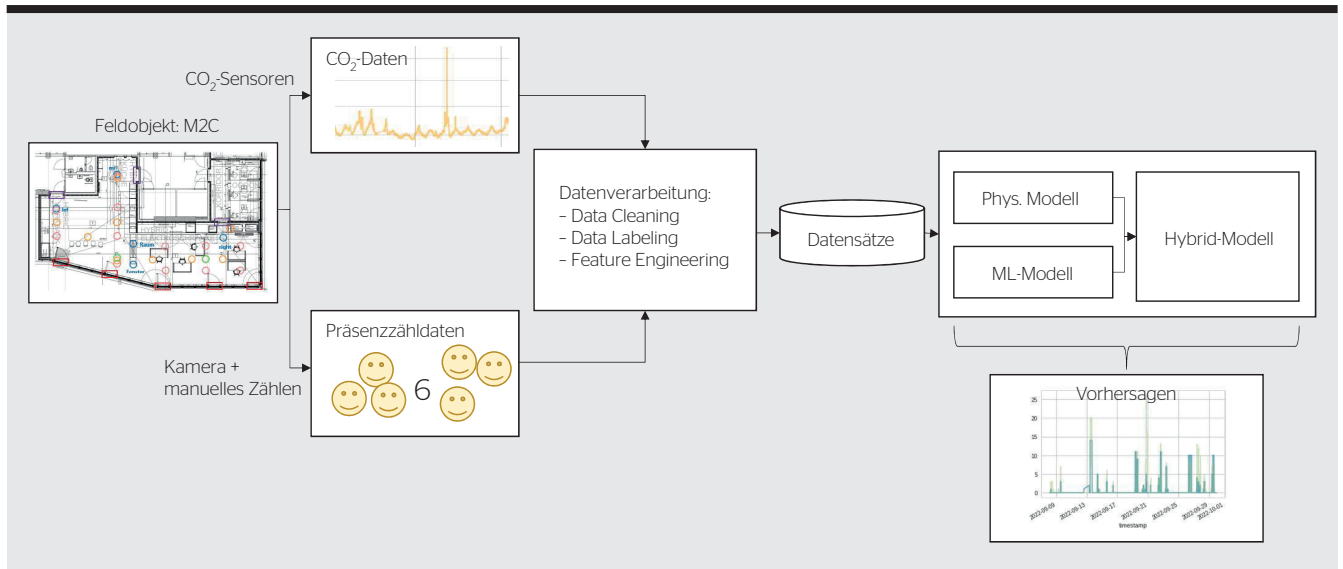


Bild 3 Blockdiagramm des ML-Präsenzalgorithmus: Die Daten zur Bestimmung der Präsenzzählungen stammen von CO₂-Sensoren, die aufbereitet und um abgeleitete Faktoren ergänzt werden. Diese angereicherten Daten werden von den Modellen zur Vorhersage genutzt.




Bild 4 Wiederkehrende Muster in der CO₂-Konzentration: Bei allen Mustern treten alle Personen gleichzeitig in den Raum ein. Bei **Muster 1** verlassen sie den Raum gleichzeitig, bevor es zu einem CO₂-Gleichgewicht kommt. Bei **Muster 2** verweilen Sie so lange, bis sich ein Gleichgewicht einstellt. Bei den weiteren Mustern kann sich kein Gleichgewicht einstellen, denn bei **Muster 3** verlassen die Personen den Raum früh, bei **Muster 4** gibt es ein Kommen und Gehen und bei **Muster 5** verlassen einzelne Personen den Raum und kommen nicht mehr zurück.

Die erste Iteration des ML-Modelles, kurz erstes Modell, definiert die Referenz und wird mit dem rohen Datensatz aus CO₂-Konzentrationen und einer Kaskade an vergangenen CO₂-Konzentrationen gefüttert. Die Genauigkeit der Prognose für die Präsenzzählung liegt für RMSE, MAE und R₂ bei: 3,2, 1,2 und 0,22.

Feature Engineering berücksichtigt CO₂-Muster.

Es zeigt sich, dass die CO₂-Konzentration alleine zur Inferenz der Präsenz nicht genügt, da dem ML-Modell nur eine Information mitgegeben wird, nämlich, wie sich eine Sequenz von CO₂-Konzentrationen mit der aktuellen Anzahl der Anwesenden verhält. Weitere Informationen können durch den Vorgang des Feature Engineerings

hinzugefügt werden. Beim Feature Engineering liegt der Fokus auf der Aufschlüsselung der CO₂-Charakteristik: Aus den Zeitreihen der CO₂-Konzentrationen lassen sich bestimmte, wiederkehrende Muster herauslesen, die durch ihren Anstieg, Plateaus, des CO₂-Konzentrationsabfalls und deren absoluter Höhe charakterisiert werden können (**Bild 4**).

Die Informationen der verschiedenen CO₂-Muster werden durch die Extraktion der Differenz erster Ordnung, abschnittsweise Gliederung in Bereiche vergleichbarer Statistik und Bestimmung der Standardabweichung und der mittleren absoluten Abweichung, linearer Trend und Hypothesentest der Stationarität, der Klassifizierung des CO₂-Abfalls formalisiert. Das sogenannte «prior likely present»-Fea-

ture, das die Genauigkeit der Vorhersage stark erhöht, wird detailliert in **Bild 5** vorgestellt.

Die Modellvorhersagen des ersten Modells sind deutlich besser, wenn PIR-Präsenzdaten hinzugefügt werden. Da diese in einer realen Anwendung nicht zur Verfügung stehen würden, sind diese mittels Feature Engineering mit dem «Prior likely present» aus den Daten abgeleitet (**Bild 5**). Durch die Differenz erster Ordnung und Filterung ergeben sich Wiggles (gelb). Es fällt auf, dass diese Wiggles vornehmlich bei Präsenz auftreten. Sie erlauben es, in einem weiteren Schritt die Präsenz regelbasiert zu bestimmen. Die Präsenz ist hier der rote Bereich zwischen zwei deutlichen Maxima der Wiggles und verbindet den Start, mit dem letzten Minimum, vor dem nächsten grossen Maximum. Die Hinzunahme des «Prior likely present» ergibt einen F1-Score beim Vorhersagen der Präsenz von 0,69, wobei die PIR-Sensoren einen kombinierten Wert von 0,92 haben.

Klare Verbesserung mit Feature Engineering

Im direkten Vergleich der Vorhersagen zur Präsenz zwischen ML-Ansatz und physikalischem Modell zeigt sich ein deutlicher Unterschied zwischen Präzision, Recall und F1-Score: 0,77, 0,75 und 0,76 vs. 0,29, 0,83 und 0,43, vgl. mit Literaturwerten für vergleichbares Setting F1-Score: 0,73 [2]. Dies ist

Modell	R2	RMSE	MAE
ML-Modell final	0,54	2,24	0,64
Physikalisches Modell	0,42	2,64	1,18
Hybrides Modell	0,48	2,37	0,67

Tabelle 2 Werte der verschiedenen Modelle.

zugleich die symptomatische Schwäche des physikalischen Modells. Das Modell reagiert sensitiv auf erhöhte CO₂-Konzentrationen und bewertet einen Grossteil der beobachteten CO₂-Konzentrationszunahmen als Präsenz. Dies führt auch zu den schlechteren Werten bei der Präsenzzählung im Vergleich zum R2-Score des ML-Ansatzes: 0,54 im Vergleich 0,42. Das bedeutet, dass 46 resp. 58% der Personenzählvarianz durch die berücksichtigten Faktoren unerklärt bleiben und somit beide Ansätze nur einen mässigen Anteil der Varianz der abhängigen Variable erklären können. Die Gründe lassen sich aus **Bild 6** ableiten. Dort wurde die Vorhersageverteilung aufgetragen, X-Achse ist die korrekte Präsenzzählung, Y-Achse ist die Modellvorhersage und am oberen Rand kann die Anzahl Stichproben einer Präsenzzählung abgelesen werden. Bei einer perfekten Übereinstimmung würde sich eine Gerade von links unten nach rechts oben ergeben. Aber bei den Vorhersagen tritt eine grosse Streuung ein und die Vorhersagegenauigkeit nimmt mit zunehmender Personenanzahl ab.

Das Diagramm lässt sich in zwei Bereiche, grün und rot, einteilen. Die Bereiche unterscheiden sich dabei in

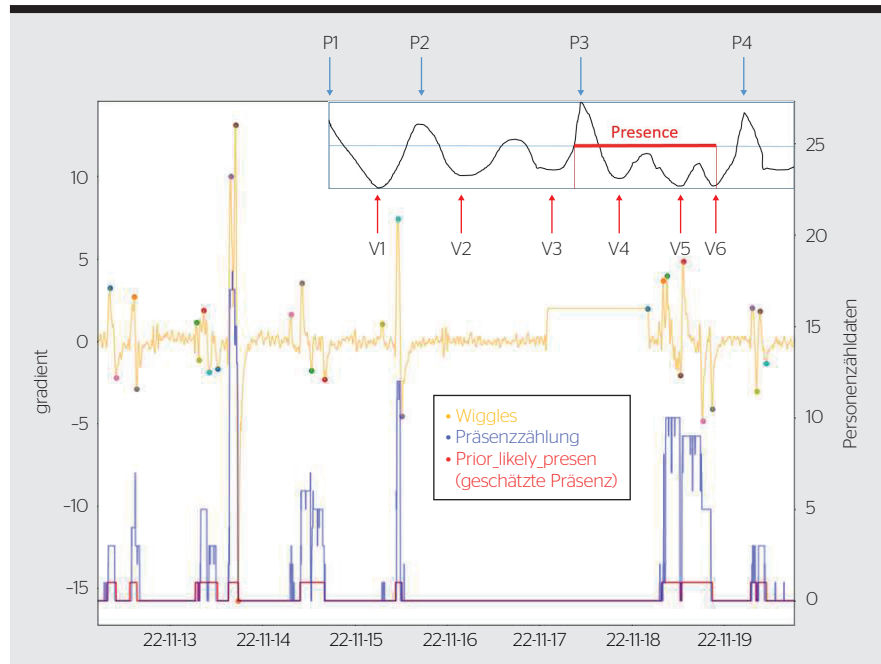


Bild 5 Feature Engineering von «Prior likely present», welches die Anwesenheit anhand der CO₂-Konzentrationsänderungsrate, Wiggles, schätzt, siehe Subgrafik.

mehreren Punkten: Im grünen Bereich wird ein R2 zwischen Vorhersage und wahren Präsenzzählungen von 0,57 erreicht; im roten Bereich ergibt sich ein negativer R2. Die Erklärung: Es liegen nur sehr wenige Samples für Präsenzzählungen > 13 vor. Zudem konnte bei grösserer Personenanzahl eine Zunahme der Aktivitäten beobachtet werden, insbesondere das Öffnen der Fenster und Türen, das sich stark auf die CO₂-Konzentration auswirkt. Diesem Umstand wird mit keinem Feature Rechnung getragen. Wird die Information bezüglich dem Raumzustand hinzugefügt (offen oder geschlossen), so

steigt R2 auf über 0,63 im Vergleich zu 0,54. Ignoriert man auch die Personenanzahl > 13, steigt der R2-Wert auf 0,65. Das finale ML-Modell liefert im Allgemeinen gute Werte zur Vorhersage der Präsenz und Präsenzzählung, das physikalische Modell liefert hingegen nur mässige Werte.

Die Leistung des hybriden Modells (**Bild 3**) liegt leicht unter dem Niveau des reinen ML-Modells, weil die Vorhersagen des physikalischen Modells relativ hoch gewichtet werden. Somit erbt das hybride Modell auch dessen Schwächen bezüglich der Präsenzvorschau. In den anderen beiden Test-

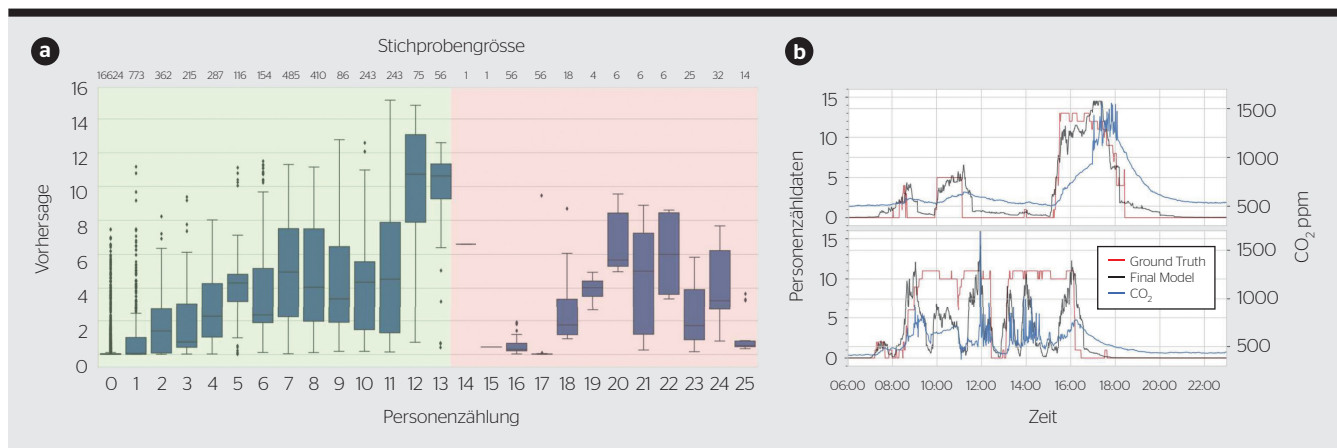


Bild 6 Gründe für die Vorhersagegenauigkeiten. **a)** Einteilung in gute und schlechte Bereiche der Vorhersagen, grün vs. rot. **b)** Beobachtungen in den einzelnen Bereichen bei vergleichbarer Anzahl Personen, aber geschlossener Raum, oben, und offener Raum, unten mit den Vorhersagen des finalen ML-Modelles, schwarz, korrekten Personenzählungen rot und der CO₂-Konzentration.

fällen, Sprint und Sizi, erzielte das hybride Modell wegen dem Stacking bessere Werte als das ML-Modell. Insgesamt zeigt sich, dass das hybride Modell stark vom ML-Modell abhängig ist. Wegen des erhöhten Implementierungsaufwands und hoher Ähnlichkeit mit ML wird in der weiteren Diskussion auf das ML-Modell und das physikalische Modell fokussiert (**Tabelle 2**):

Der initiale Implementierungsaufwand für das gut automatisierbare und skalierbare ML-Modell ist relativ gering: Neue Informationen können einfach mittels Feature Engineering hinzugefügt werden. Die initiale Erstellung des physikalischen Modells kann hingegen nur bedingt automatisiert werden (Raumvolumen oder Parameterschätzung). Beim physikalischen Modell können zudem neue Features nicht direkt integriert werden. Das finale ML-Modell hat Schwächen bei der Adaptierbarkeit und kann wie erwartet nicht auf ungesehene Objekte angewendet werden, denn es braucht

gelabelte Daten, die teuer sind. Die Adaptierbarkeit des physikalischen Modells ist gut, solange die zugrunde liegenden Annahmen gültig bleiben. Die Einfachheit der Umsetzung hängt von der Verfügbarkeit und Güte der Schätzung der Eingangsparameter, wie Raumgrösse, Geschlechteranteil und Lüftungspraktiken ab, wobei natürlich belüftete Räume die kritischsten Szenarien darstellen.

Leistung der Modelle überzeugt, aber ...

Am Ende liegt die Erkenntnis vor, dass das ML-Modell durch die Abhängigkeit von gelabelten Daten und mangelnder Adaptierbarkeit für den Einsatz zur Überwachung der Raumluftqualität nur beschränkt, unter hohen Kosten, genutzt werden kann. Die Leistungsvorteile überwiegen die Kosten nicht, weshalb das physikalische Modell hinsichtlich Performanz und Kosten zu bevorzugen ist. Letzteres zeigt insbesondere in Situationen, in denen die Lüftungspraktiken und Eckwerte des

Raumes bekannt sind, zufriedenstellende Werte, und lässt sich auf alle Räumlichkeiten, für die das zutrifft, anwenden.

In zukünftigen Arbeiten wird der Fokus auf das ML-Modell gelegt. Insbesondere die Adaptierbarkeit und Möglichkeiten zur Evaluation des Raumzustands versprechen einiges, um neben einer deutlichen Performanzsteigerung auch einen breit gefächerten Einsatz zu ermöglichen.

Referenzen

- [1] xgboost.readthedocs.io/en/stable
- [2] www.mdpi.com/2071-1050/14/21/14644
- [3] medium.com/@brijesh_soni/stacking-to-improve-model-performance-a-comprehensive-guide-on-ensemble-learning-in-python-9ed53c93ce28

Autoren

Michael Locher ist Projektleiter Data Science.
→ Empa, 8600 Dübendorf
→ michael.locher@empa.ch

Dr. **Erfan Haghghi** ist Head of Research and Product Development.
→ Oxygen at work, 8002 Zürich
→ erfan@oxygenatwork.org

Die Untersuchung wurde finanziell von Innosuisse unterstützt.

RÉSUMÉ

Lire l'air pour révéler la présence

Capteurs

Les informations relatives à l'occupation des locaux, respectivement à la présence, sont précieuses pour améliorer l'efficacité énergétique, le confort intérieur, la qualité de l'air ambiant, la fonctionnalité, la sécurité et, finalement, la rentabilité des bâtiments. Il existe, d'une part, différentes catégories d'estimation de la présence – présence, comptage de présences, localisation de la présence, identité de la présence – et, d'autre part, différents capteurs pour les déterminer.

Pour la détection automatique de la présence, on utilise typiquement des détecteurs de mouvement ou de présence, le plus souvent des capteurs infrarouges passifs (PIR), et parfois des capteurs optiques. Outre ces méthodes de mesure directes, une estimation de la présence peut également être réalisée de manière indirecte, par exemple à l'aide de données provenant de compteurs électriques, de données d'utilisation du réseau WLAN, ou de capteurs de température et de qualité de l'air ambiant tels que des capteurs de CO₂.

L'évaluation de la température et de la qualité de l'air ambiant, en particulier de la concentration de CO₂, constitue une manière intéressante, rentable et non intrusive pour

obtenir des informations sur la présence et le comptage des présences. Par exemple, si le nombre de personnes présentes augmente, la concentration de CO₂ augmente généralement aussi. La relation exacte entre la présence, le nombre de personnes présentes et la concentration de CO₂ est toutefois hautement non linéaire et dépend de nombreux facteurs. La présente étude compare la détermination de la présence au moyen d'un modèle d'apprentissage automatique avec celle basée sur l'utilisation d'un modèle physique. Elle a montré que le modèle reposant sur l'apprentissage automatique ne peut être utilisé que de manière limitée et à un coût élevé en raison de sa dépendance vis-à-vis des données étiquetées et de son manque d'adaptabilité pour la surveillance de la qualité de l'air ambiant. L'utilisation du modèle physique est préférable en termes de performance et de coûts. Ce dernier présente des valeurs satisfaisantes, en particulier dans les situations où les pratiques en matière de ventilation et les valeurs de référence de la pièce sont connues, et peut être appliqué à tous les locaux pour lesquels ces spécifications s'appliquent.