

# Einsatz von Decision Tree Learning zur Positionsbestimmung durch Beacons

Ali Sahin<sup>1</sup>, Jakob Pelz<sup>2</sup>  
Betreuer<sup>3</sup>: I. Hoffmann, K. Lehmann, K. Sagert

**Abstract:** Location-Aware-Systeme in öffentlichen Einrichtungen können die Orientierung und User Experience von Besuchern drastisch verbessern. Um dies zu gewährleisten muss eine zuverlässige Positionsbestimmung innerhalb von Gebäuden eingesetzt werden. Da das weit verbreitete Global Positioning System (GPS) im Gebäude nur unzureichend zur Verfügung steht, wird auf die Technologie der Beacons zurückgegriffen, die auf dem Bluetooth Low Energy (BLE) Standard aufbaut. Diese wissenschaftliche Arbeit beschäftigt sich mit dem Ansatz, mithilfe der Beacons eine möglichst genaue Positionsbestimmung in Räumen zu erreichen, unter der Berücksichtigung, dass der eingesetzte Algorithmus auf mobilen Endgeräten performant einsetzbar ist. Hierzu wird erstmal die Zuverlässigkeit der Beacon-Signale in einem Messversuch untersucht. Unter anderem wird gezeigt, dass Signalerkennungen und RSSI-Ermittlung hardwareabhängig sind, bei größeren Entfernungen die Signale stärker schwanken und fehleranfälliger werden. Anschließend wird unter der Verwendung von Decision Tree und Fingerprinting ein neues Konzept der Positionsbestimmung vorgestellt. Durch die Unzuverlässigkeit der Beacon-Signale sinkt die Genauigkeit des Entscheidungsbaumes und es kommt zu Fehlern der Positionsbestimmung. Ferner kann mithilfe des vorgestellten Prototyps gezeigt werden, dass die Genauigkeit der Positionsbestimmung durch die Anzahl der Beacon-Signale abhängig ist.

## 1 Einleitung

Mit der Einführung des neuen Betriebssystems iOS7 im Jahr 2013 von Apple Inc. wurde ebenfalls eine Lösung für standortbezogene Dienste auf Basis von Bluetooth Low Energy (BLE) Technologie vorgestellt [Ne14]. Diese Lösung, genannt iBeacons, sind energieeffiziente Sender, die mit mobilen Endgeräten über Bluetooth unidirektional kommunizieren. Damit ermöglichte Apple neue Anwendungsmöglichkeiten für Location-Awareness-Systeme. Unter anderem wurde eine Optimierung einer Lagerverwaltung [Br15] und eine Flughafen Navigation [Lo17] damit ermöglicht. Diese Technologie wird größtenteils für Indoor-Navigation eingesetzt und könnte im Einsatz in öffentlichen Gebäuden zur Erkennung interessanter Orte verwendet werden, wie zum Beispiel Fahrkartenschalter, Geldautomaten oder wichtigen öffentlichen Räume.

Die Problematik in diesem Gebiet grenzt sich auf die Auswahl des Algorithmus zur Positionsbestimmung anhand der Beacon-Daten ein. Im Rahmen des Forschungsprojektes setzt sich die vorgelegte Arbeit mit der Positionsbestimmung in

---

<sup>1</sup> Hochschule Esslingen, Informationstechnik, Flandernstraße 101, 73732 Esslingen, alsait03@hs-esslingen.de

<sup>2</sup> Hochschule Esslingen, Informationstechnik, Flandernstraße 101, 73732 Esslingen, japeit00@hs-esslingen.de

<sup>3</sup> Fraunhofer IAO | Anwendungszentrum KEIM, Flandernstraße 101, 73732 Esslingen

einem öffentlichen Gebäude auseinander. Dabei liegt der Fokus auf die Entwicklung eines Prototyps auf Basis von Machine Learning Konzepten, um ein mobiles Endgerät innerhalb, bzw. außerhalb eines Raumes zu orten. Die Anforderungen beschränken sich auf eine möglichst genaue Positionsbestimmung, den Einsatz von einer geringen Anzahl an Beacons im Raum und der Echtzeitberechnung der Position auf mobilen Endgeräten. Damit ableitend ist auch die Performance, bezüglich der Schnelligkeit, Stromverbrauch und Speicherkapazität, zu berücksichtigen, da diverser mobile Endgeräte durch ihre Hardware eingeschränkt sind.

Die vorliegende Arbeit gliedert sich in folgende Kapitel. Zunächst wird der aktuelle Stand der Forschung im Bereich Positionsbestimmung durch den Einsatz von Beacons untersucht. Im Anschluss werden, als Beitrag dieser Arbeit, Versuchsreihen zur Messung der Beacon-Signale untersucht und anschließend wird ein Konzept zur Positionsbestimmung und Raumerkennung mittels Decision Tree Learnings vorgestellt. Folgend wird ein Demonstrator beschrieben, der eine konkrete Implementierung zur Positionsbestimmung und Raumerkennung zeigt, wodurch der Tragfähigkeitsnachweis für die vorliegende Arbeit erbracht werden soll. Den Abschluss bildet eine Zusammenfassung und Ausblick auf weitere Forschung in diesem Themenbereich.

## 2 Stand der Forschung

In diesem Kapitel werden bereits existierende Lösungen im Kontext der Positionsbestimmung durch den Einsatz von Beacons und Endgeräten vorgestellt. Die Untersuchung der bestehenden Arbeiten und dessen Auswertung bildet die Grundlage für den Handlungsbedarf dieser Arbeit. Die ersten beiden Methoden nutzen mathematische Grundfunktionen, um Positionsbestimmungen mit dem Einsatz von Beacons zu realisieren, während die weiteren Beacon-Eigenschaften nutzen.

**Trilateration** Mithilfe der Trilateration kann die Position eines Empfängers bestimmt werden, indem der Abstand zu drei bekannten Punkten berechnet wird. Zu jedem bekannten Punkt wird der Abstand gemessen und ein Radius um diesen Punkt gezogen. Der Schnittpunkt der drei Radien ist die gesuchte Position des Empfängers [MH95].

**Triangulation** Die Triangulation nutzt sowohl den Abstand als auch die Winkel zur Berechnung der Position. Wenn die Winkel aller Sender zum Benutzer bekannt sind oder der Winkel vom Benutzer zum Sender kann durch den Schnittpunkt der entstandenen Vektoren die Position des Empfängers bestimmt werden. [KSW04].

**Zeitmessungsverfahren** Das Time-Of-Arrival (TOA) nutzt die Dauer der gesendeten Signale und berechnet mit dem Wissen der Ausbreitungsgeschwindigkeit die Distanz. "Je weiter die Basisstation vom Empfängergerät entfernt ist, desto mehr Zeit benötigt das Signal bis zur Ankunft am Empfänger. Anhand der Signallaufzeiten und einer bekannten

Ausbreitungsgeschwindigkeit ist die Berechnung der Entfernungen zu den Basisstationen möglich." [Br15, S. 17]

**Signalstärkemessungsverfahren** Mit Hilfe des empfangenen Signals (RSSI) ist eine Messung des Abstands vom Beacon zum Endgerät möglich. "Da die Signalstärke nur in der Theorie einen quadratischen Abfall verzeichnet, wird hierbei oft auf ein Verlustmodell zurückgegriffen, das die Umrechnung der empfangenen Signalstärke (meist in Dezibel Milliwatt) auf ein metrisches Maß z.B. Meter zulässt." [Br15, S. 17]

In dieser wissenschaftlichen Arbeit wurden folgende Verfahren genutzt, um eine neue Lösung zur Positionsbestimmung vorzustellen. Dabei wird eine Kombination der vorgestellten Methoden verwendet.

**Fingerprinting** Das Fingerprinting benutzt charakteristische Übereinstimmungen von RSSI-Signalen um die Position des Nutzers zu bestimmen. Das System muss in einem Offline und Online Modus arbeiten. Im Offline Modus (Trainingsmodus) speichert das System laufend die Signalstärken für einen späteren Vergleich ab. Somit entsteht eine Signalkarte, in denen die Objekte in verschiedenen Positionen verschiedene Signalstärken empfangen. Die Erstellung dieser Karte beginnt mit der Einteilung in Bestimmte Bereiche, bspw. mithilfe eines Gebäudeplans. Somit hat man die Grundlage für die Bestimmung der Position anhand der Signalstärke im Online Modus [FH15].

**Decision Tree Learning** Decision Tree Learning ist ein Ansatz zur Vorhersage von Klassen anhand von eingegeben Variablen. Dabei ist die Anzahl der Variablen und Klassen flexibel wählbar [SL91]. Der Ansatz fällt in den Bereich Machine Learning (ML) [GH88]. Zu den Aufgaben von Decision Tree gehören unter anderem Klassifizierung, Regression und Clustering. Anstatt eine vorprogrammierte Software zu schreiben, ist Machine Learning

„the ability to learn without being explicitly programmed.“

Arthur Samuel [MF90, S. 11].

### 3 Messergebnisse

In diesem Kapitel werden Versuchsreihen aufgestellt, um die Qualität und die Zuverlässigkeit von Beacons zu überprüfen. Eine der ausgeführten Versuchsreihen in diesem Beitrag hat sich mit den empfangenen RSSI-Werten [Ap14] aus unterschiedlichen Entfernungen befasst. Es sollte herausgestellt werden, wie die Entfernung sich auf den RSSI-Wert auswirkt. Dafür wurden mehrere Messwerte aus einer Entfernung von ein bis neun Meter aufgenommen und ausgewertet. Um die Abhängigkeiten von Hard- und Software darzustellen, wurden zwei Endgeräte verwendet. Zum einen das von Samsung hergestellte Galaxy S6 und das One+. In den Diagrammen (Abbildung 1) sind die




Abb. 1: Mittelwert und Standardabweichung

Mittelwerte und Standardabweichungen auf den einzelnen Entfernungen dargestellt. Während den Messungen konnten wir feststellen, dass u.a.

- Die Signale vom Smartphone nicht in regelmäßigen Abständen empfangen werden
- Signalerkennung und RSSI-Ermittlung smartphone- bzw. hardwareabhängig ist
- mit der Entfernung schwanken die Signale stärker und die Fehleranfälligkeit steigt

Durch die Messergebnisse entsteht das Ergebnis, dass man sich nicht auf die Regelmäßigkeit der Beacon-Signale verlassen kann und für eine genauere Bestimmung der Position mehrere Beacons gebraucht werden.

## 4 Konzept

Die Realisierung einer Positionsbestimmung soll mithilfe von mehreren Messungen und das Training eines KI-Klassifizierungsmodell erfolgen. Hierbei wird das Verfahren des Fingerprinting verwendet, indem an verschiedenen Positionen bzw. Bereichen RSSI-Daten in Abhängigkeit zu den Beacons gesammelt werden. Mithilfe des ML-Algorithmus Decision Tree (DT) soll aus den gesammelten Daten ein Entscheidungsbaum entworfen werden, der eine Positionsbestimmung einer Person in einem Raum ermöglicht. Dieser Entscheidungsbaum bildet das Klassifizierungsmodell, das für den Menschen leicht nachvollziehbar ist, im Gegensatz zu anderen ML-Methoden. Dazu muss der Entscheidungsbaum vorerst von Daten trainiert und getestet werden. Hierzu sind mehrere Schritte notwendig:

1. Die gemessenen Daten werden zusammengeführt und manuell klassifiziert. Die Klasse der Datensätze am Ende bestimmen an welcher Position man sich befindet.
2. Die klassifizierten Daten werden in zwei Datensätze aufgeteilt: Trainings- und Testdaten, in Relation von 80 zu 20.
3. Mithilfe der Trainingsdaten wird ein Entscheidungsbaum erzeugt und mittels der Testdaten die Genauigkeit dieses Baumes bestimmt.

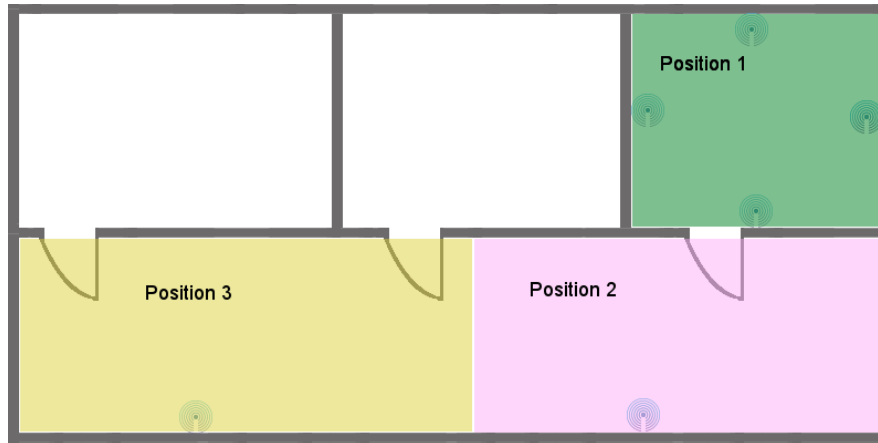


Abb. 2: Versuchsaufbau

## 5 Realisierung

Für die Realisierung wurde ein Versuch durchgeführt, welches das Ziel hat zu erkennen, an welchen von drei vorher definierten Punkten sich eine Person aufhält. Für diesen Versuch wurden sechs Beacons in Betrieb genommen: vier Beacons wurden in einem Raum und die zwei restlichen Beacons wurden im Flur angebracht.

Es wurden drei Positionen definiert:

- Im Raum: Mit diesem Versuch soll auch bestätigt werden, dass es möglich ist nachzuprüfen, ob sich eine Person im Raum aufhält.
- Vor dem Raum (im Flur) sowohl mit offener als auch mit geschlossener Türe.
- Ebenfalls im Flur

Für jede Position wurden mithilfe einer Aufzeichnungsapplikation für Android 500 bis 1000 Datensätze über die RSSI-Signale der Beacon-Geräte aufgezeichnet und je nach ihrer Position manuell klassifiziert. Die Aufzeichnungsapplikation wurde in Eigeninitiative entwickelt und zeichnet die Beacon-Signale in Abhängigkeit zueinander auf, was bedeutet, dass die Kombination aus mehreren Beacon-Signalen die Positionssignatur bzw. das Fingerprint bestimmt. Die Klassifizierung wurde folgendermaßen gewählt:

- Position 1 → Klasse A
- Position 2 → Klasse B
- Position 3 → Klasse C

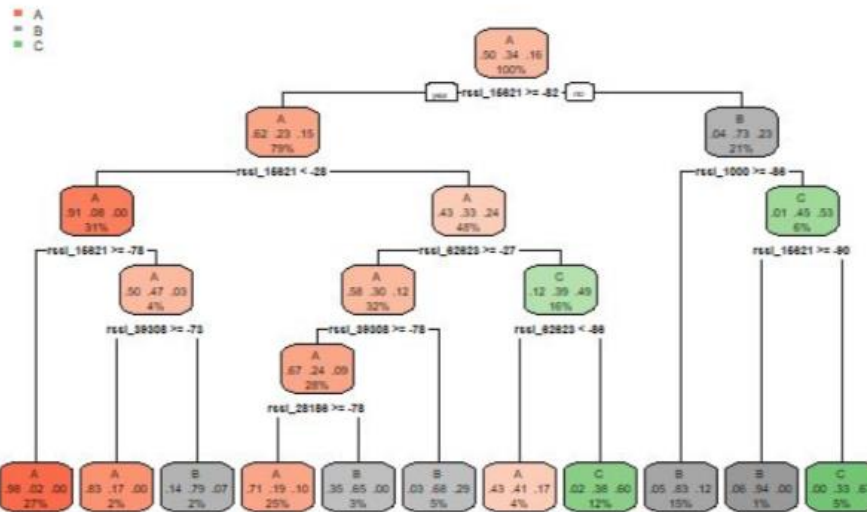


Abb. 3: Entscheidungsbaum zur Positionsbestimmung

Nach der Klassifizierung werden die Daten im Verhältnis 80 zu 20 in Trainingsdaten und Testdaten aufgeteilt. Zur Entwicklung eines Entscheidungsbaumes wird die statistische Programmiersprache R und die benötigte Bibliothek rpart verwendet. Indem der Bibliothek rpart die Trainingsdaten eingereicht werden, kann der Entscheidungsbaum (siehe Abbildung 3) generiert und anschließend als if-Klauseln in einer beliebigen Programmiersprache implementiert werden.

Der Entscheidungsbaum wurde testweise in einer prototypischen, hybriden Applikation integriert, um den Versuch (Abbildung 2) durchzuführen. In dieser Applikation werden die Beacon-Signale gescannt und direkt in den Entscheidungsbaum eingeführt. Durch die Unzuverlässigkeit der Beacon-Signale sinkt die Genauigkeit des Entscheidungsbaumes und es kommt zu Fehlern der Positionsbestimmung. Um die Genauigkeit der Positionsbestimmung zu erhöhen müssen mehrere Beacon-Signale gesammelt und der Mittelwert gebildet werden. Durch diesen Vorgang steigt die Genauigkeit des Entscheidungsbaumes; je mehr Beacon-Signale gesammelt werden, umso genauer sind die Ergebnisse. Dadurch erhöht sich aber auch die Zeit für die Berechnung und der Erhalt der Ergebnisse.

## 6 Zusammenfassung und Ausblick

Die vorliegende Arbeit hat sich mit dem Thema Positionsbestimmung in öffentlichen Gebäuden mittels BLE Beacons auseinandergesetzt und neue Ansätze dieser Thematik vorgestellt. Aus der Kombination aus Fingerprinting und dem ML-Konzept Decision Tree ist es möglich den Standort im Gebäude zu lokalisieren.

Trotz dieses Ergebnisses gilt es noch einige Probleme zu lösen. Wie man aus den Messergebnissen deuten konnte, ist die Signalerkennung und RSSI- Ermittlung smartphone- bzw. hardwareabhängig. Das bedeutet, dass für jedes Android-Gerät und zusätzlich für jede Android-Version unterschiedliche RSSI-Werte ermittelt werden könnten. Daher ist eine zusätzliche Forschung und Datenerfassung im Bereich der Diversität der verschiedenen mobilen Endgeräte notwendig. Es müssen verschiedene Android-Geräte (Samsung, HTC, Sony, etc.) unterschiedlicher Android-Versionen mit in die Datenerfassung einfließen, um eine Großzahl der Android-Geräte kompatibel zu machen. Zusätzlich muss man auch erste Versuche mit iOS-Geräten durchführen, da sie neben Android den zweitgrößten Marktanteil mit circa 33% in Deutschland besitzen [St18].

Weiter ist zu beachten, wie die Wirtschaftlichkeit des Beacons-Einsatzes zu verbessern ist. Es sollten Versuche durchgeführt werden, indem ermittelt wird, welche Anzahl an Beacons man benötigt, um eine gute Genauigkeit zu erhalten und dabei so wenig Beacons wie möglich zu verwenden. Werden zu viele Beacons eingesetzt, werden die Kosten der Beschaffung in die Höhe getrieben.

Zusätzlich können zukünftig noch alternative ML-Konzepte, wie Neuronale Netze anstatt des verwendeten Decision Trees, verwendet werden, um eventuelle Effizienzsteigerungen zu erzielen. Unter anderem besitzen Neuronale Netze den Vorteil eigene Features aus den Rohdaten zu generieren. Außerdem sind diese robust gegenüber Ausreißer in der Falschklassifikation beim Training und gegenüber Rauschen.

### Literaturverzeichnis

- [Br15] Breitbach, T.: Einsatz von iBeacons in der modernen Lagerverwaltung, 2015.
- [FH15] Faragher, R; Harle R.: „Location fingerprinting with bluetooth low energy beacons“, In: IEEE journal on Selected Areas in Communications 33.11 (2015), S. 2418–2428.
- [GH88] Goldberg, D.; Holland, J.: „Genetic algorithms and machine learning“, In: Machine learning 3.2 (1988), S. 95–99.
- [Ap14] Apple Inc.: Getting Started with iBeacon, <https://developer.apple.com/ibeacon/Getting-Started-with-iBeacon.pdf>, zugegriffen am 25. Mai 2018. 2014.

- [KSW04] Kleinberg, J.; Slivkins, A.; Wexler, T.: „Triangulation and embedding using small sets of beacons“, In: Foundations of Computer Science, 2004. Proceedings. 45th Annual IEEE Symposium on. IEEE. 2004, S. 444–453.
- [Lo17] Lomas, N.: „Gatwick Airport now has 2,000 beacons for indoor navigation.“, <https://techcrunch.com/2017/05/25/gatwick-airport-now-has-2000-beacons-for-indoor-navigation/>, zugegriffen am 22. Mai 2018. 2017.
- [MF90] McCarthy, J.; Feigenbaum, E.: In Memoriam Arthur Samuel: pioneer in machine learning. 1990.
- [MH95] Murphy, W; Hereman, W.: „Determination of a position in three dimensions using trilateration and approximate distances“, In: Department of Mathematical and Computer Sciences, Colorado School of Mines, Golden, Colorado, MCS-95 7 (1995), S. 19.
- [Ne14] Newman, N.: „Apple iBeacon technology briefing“, In: Journal of Direct, Data and Digital Marketing Practice 15.3 (2014), S. 222–225.
- [SL91] Safavian, R.; Landgrebe, D.: „A survey of decision tree classifier methodology“, In: IEEE transactions on systems, man, and cybernetics 21.3 (1991), S. 660–674.
- [St18] Statista: „Marktanteile der führenden mobilen Betriebssysteme an der Internetnutzung mit Mobiltelefonen in Deutschland von Januar 2009 bis März 2018.“, <https://de.statista.com/statistik/daten/studie/184332/umfrage/marktanteil-der-mobilen-betriebssysteme-in-deutschland-seit-2009/>, zugegriffen am 24. Mai 2018. 2018.