

Künstliche neuronale Netze in der Immobilienwertermittlung

Artificial Neural Networks in Real Estate Valuation

Sabine Horvath, Matthias Soot, Alexandra Weitkamp, Hans Neuner

Die Forderung nach Möglichkeiten einer automatisierten Wertermittlung scheitert regelmäßig an der Bewertung kaufpreisarmer Lagen. Eine Auswertung der kaufpreisarmen Lagen in aggregierten größeren Stichproben gelingt mit klassischen Vorgehensweisen nicht. Ein Grund dafür können auftretende Nicht-linearitäten sein. Daher werden in diesem Beitrag Künstliche Neuronale Netze (KNN) als eine nichtparametrische und nichtlineare Methode der etablierten klassischen Multiplen Linearen Regression (MLR) gegenübergestellt. Anhand zweier Beispieldatensätze – Vergleichsfaktoren für Einfamilienhäuser in Hannover und niedersachsenweite Liegenschaftszinssätze – werden beide Methoden auf ihre Leistungsfähigkeit untersucht. Anhand von etablierten Gütemaßen erfolgt die Bewertung der Methoden.

Liegen nichtlineare Zusammenhänge vor, sind im Fall von hinreichend großen Stichproben KNN der MLR überlegen, was sich für die Auswertung der niedersachsenweiten Liegenschaftszinssätze bestätigt hat. Im Fall der Einfamilienhäuser in Hannover liefert die MLR aufgrund der geringen Datenmengen die bessere Schätzung. Eine Vergrößerung der Stichprobe auf Basis einer strukturerhaltenden Methode hat sich in dieser ersten Untersuchung als vorteilhaft erwiesen. Aufgrund des Bedarfs an größeren Datenmengen wird die Stichprobengenerierung mittels Simulationsmethoden sowie die Nutzbarmachung von fehlerhaften oder unvollständigen Daten Fokus zukünftiger Forschung sein.

Schlüsselwörter: Künstliche Neuronale Netze, Multiple Lineare Regression, Immobilienbewertung, kaufpreisarme Lagen

An automatic real estate valuation fails regularly on the appraisal of areas with only few transactions. Evaluating areas with few transactions in aggregated samples does not work with classic valuation methods probably caused by non-linearities. Therefore, artificial neural networks (KNN) as a non-parametric and non-linear method will be compared to the established classic multiple linear regression (MLR). Based on two samples – comparison factors of single-family houses in Hannover and state-wide property rates in Lower Saxony – the two methods are compared on their performance, based on established quality criteria.

If non-linear relations are given, in case of an adequate sample size KNN perform better than the MLR. The evaluation of the property yields throughout Lower Saxony confirms this statement. In the case of the single-family houses in Hannover, the MLR leads to superior prediction results due to the small sample size. An enlargement of the sample size by a simulation preserving the data structure leads to beneficial results in a first investigation. Due to the need for large sample sizes, the generation of samples based on simulations as well as the utilization of erroneous and incomplete data will be the focus of future research.

Keywords: Artificial neural networks, multiple linear regression analysis, real estate valuation, areas with few transactions

1 MOTIVATION

Die praktische Immobilienbewertung gerät an ihre Grenzen, wenn die Auswertung mit linearen Modellen insbesondere Randbereiche unzureichend erfasst. Auch liegen vielfach nicht genügend Daten für einzelne Teilmärkte vor, was zur Notwendigkeit teilmarktübergreifender Auswertungen führt – verbunden mit der Konsequenz, zwar die Stichprobenanzahl deutlich zu erhöhen, aber stattdessen mit heterogenen Datensätzen konfrontiert zu werden. Aussagen einzelner Teilmärkte in kaufpreisarmen Lagen sind nur schwerlich aus einer teilmarktübergreifenden Auswertung zu generieren: Dies trifft sowohl für räumliche als auch für sachliche Teilmärkte zu.

Je schwieriger sich die Datenlagen der Teilmärkte gestalten (wenige Kauffälle, viele Ausreißer), desto aufwendiger ist in der Regel die Ermittlung der Verkehrswerte. In der Praxis steigen jedoch die Anforderungen an eine zeitnahe Auswertung, die in immer kürzer werdenden Abständen wiederholt werden soll. Dies zieht den Bedarf an automatisierten Verfahren (sogenannte Automated Valuation Models – AVM) nach sich.

Mit diesem Artikel wird ein Beitrag zur Bewertung kaufpreisarmer Teilmärkte aus teilmarktübergreifenden Auswertungen mit AVMs geleistet: Als teilmarktübergreifende Auswertung werden einerseits sachliche Teilmärkte aggregiert (sachliche Teilmärkte der Einfamilienhäuser in Hannover) und andererseits räumliche Teilmärkte zusammengefasst (bundeslandweite Auswertung in Niedersachsen für die Ableitung von Liegenschaftszinssätzen). Methodisch werden Künstliche Neuronale Netze (KNN) als eine nichtparametrische Methode der in der Wertermittlung etablierten klassischen Multiplen Linearen Regression (MLR) gegenübergestellt. Es wird untersucht, ob und unter welchen Voraussetzungen eine KNN-Modellierung kaufpreisarmer Teilmärkte besser erfassen kann.

2 AKTUELLER STAND ZUM EINSATZ DER KNN IN DER WERTERMITTLUNG

Der Zusammenhang zwischen dem Marktwert einer Immobilie und dessen Eigenschaften wird in der Wertermittlung typischerweise durch eine lineare/linearisierte Funktion im Rahmen der MLR modelliert. Zahlreiche Studien haben jedoch eine nichtlineare Struktur der hedonischen Preisfunktion nachgewiesen /Lisi 2013/, /Fan & Xu 2009/, /Mimis et al. 2013/, /Din, Hoesli & Bender 2001/, /Worzala, Lenk & Silva 1995/, /Halvorsen & Pollakowski 1981/. Um dies zu modellieren, erweisen sich KNN als eine nützliche Alternative. /Tay & Ho 1992/ gehören zu den ersten, die KNN für Bewertungsaufgaben einsetzten. In ihrer Studie vergleichen sie die Leistung von MLR mit KNN bei der Schätzung der Kaufpreise von Wohnungen in Singapur und kommen zum Schluss, dass KNN eine nützliche Alternative zum MLR-Modell sind.

Verschiedene Studien, die in den nächsten zweieinhalb Jahrzehnten durchgeführt wurden, zeigen, dass KNN in der Immobilienbewertung der MLR überlegen sind. /Mimis et al. 2013/ verwenden interne physikalische (Strukturqualität und -quantität) und externe Umweltmerkmale (Nachbarschaft, Verkehrsanbindung) der Immobilien, um Hauspreise in Athen zu präzisieren. Sie vergleichen die Ergebnisse der Regressionsanalyse mit denen eines KNN und

kommen zu dem Schluss, dass der KNN-Ansatz in den meisten Fällen der MLR überlegen ist, da er mit nichtlinearen Beziehungen umgehen kann. /Núñez Tabales et al. 2013/ ziehen ähnliche Schlüsse für Hauspreise in Südspeanien: Neuronale Netze führen zu einer besseren Anpassungsfähigkeit, die in ihrem Fall durch den Bestimmungskoeffizienten ausgedrückt wird. /Morano et al. 2015/ wenden KNN auf die Bewertung von Immobilienmarktwerten am Beispiel von Wohnimmobilien in einem engen räumlichen Teilmarkt in Bari (Italien) an. Die Interpretation ihrer Ergebnisse ist jedoch fragwürdig, da der Stichprobenumfang von 90 Transaktionen, mit denen das KNN trainiert wird, viel zu klein ist.

/Nguyen & Cripps 2001/ verweisen erstmalig auf entsprechend benötigte Datenmengen, um eine gute Prädiktion mit KNN zu erreichen, und auf die Wichtigkeit der zu wählenden Gütekriterien für die Beurteilung der Ansätze. /Zurada et al. 2011/ vergleichen mehrere Lernverfahren (inkl. KNN) mit Regressionsverfahren (inkl. MLR) und kommen zu dem Schluss, dass für homogene Datensätze die nicht-traditionellen Regressionsverfahren (darunter fassen die Studienautoren die Support Vector Regression, die Additive Regression sowie M5P-Regressionsbäume zusammen) besser abschneiden und im Fall von heterogenen Datensätzen und überlappenden Clustern Lernverfahren eine bessere Prädiktion liefern. Sie zeigen ebenfalls auf, dass bisher zu geringe Datenmengen für die Modellierung mit Lernverfahren verwendet wurden.

Im Ergebnis ist festzuhalten, dass KNN bisher lediglich auf ausgewählten sachlichen und räumlichen Teilmärkten angewandt wurden. Nationale (insbesondere auf deutsche Teilmärkte bezogene) Untersuchungen hinsichtlich der Verwendbarkeit von KNN in der Wertermittlung fehlen bislang. Anknüpfend an den Bedarf, auch kaufpreisarmer Lagen auszuwerten zu müssen /Soot et al. 2017/, stellt sich die Forschungsfrage, ob KNN in aggregierten Teilmärkten, die einer nichtlinearen Modellierung bedürfen, der Auswertung mit MLR überlegen sind.

3 FORSCHUNGSDESIGN FÜR DEN VERGLEICH DER MLR UND DER KNN IN DER WERTERMITTLUNG

Zum Vergleich der Methoden MLR und KNN in der Wertermittlung erfolgt eine Aggregation von Teilmärkten: Es werden sowohl sachliche als auch räumliche Teilmärkte zusammengefasst ausgewertet, sodass einzelne kaufpreisarmer Teilmärkte in einen großen Teilmarkt einbezogen sind. Als sachliche Teilmärkte werden Einfamilienhäuser gewählt: Hierzu werden die Teilmärkte freistehende Ein- und Zweifamilienhäuser, Doppelhaushälften, Reihenmittel- und Reihenendhäuser sowie auch Villen gemeinsam ausgewertet. Für eine räumliche Aggregation werden die räumlichen Teilmärkte der Liegenschaftszinssätze auf Ebene des Bundeslands Niedersachsen zusammengefasst. Beide Aggregationen enthalten sowohl kaufpreiare als auch kaufpreisarmer Teilmärkte. Durch die Aggregation liegt eine jeweils genügend große Stichprobe vor, die allerdings nichtlinear modelliert werden müsste.

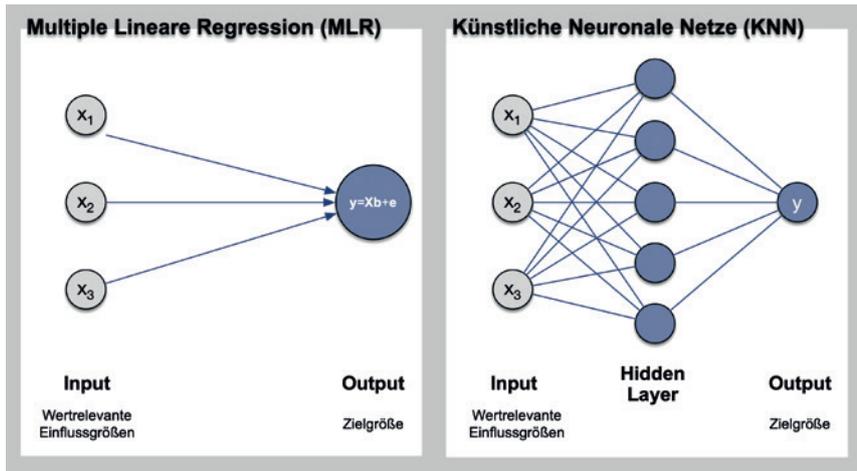


Abb. 1 | Gegenüberstellung der Methoden MLR und KNN

3.1 Einführung in die Methodik

Es werden die Multiple Lineare Regression und die Künstlichen Neuronale Netze vergleichend gegenübergestellt (Abb. 1). MLR haben sich in der Praxis etabliert, erreichen aber bei Nichtlinearitäten schnell ihre Grenzen. KNN haben sich in anderen Bereichen für eine nichtlineare Modellierung und in ersten Anwendungen in der Wertermittlung als erfolgversprechend erwiesen. Im Folgenden werden KNN und MLR kurz eingeführt.

Der Methodenvergleich der KNN mit herkömmlicher MLR erfolgt über etablierte Gütemaße (siehe Abschnitt 3.2): Es werden die Wurzel des mittleren quadratischen Fehlers (Root Mean Square Error – RMSE), der mittlere absolute Fehler (MAE), der mittlere absolute prozentuale Fehler (MAPE) und die Fehler unter 5 % (EB5) verwendet. Damit ist auch eine Vergleichbarkeit mit vorhergehenden Untersuchungen möglich. Abschließend wird das Versuchsdesign vorgestellt.

3.1.1 Multiple Lineare Regressionsanalyse (MLR)

In der Wertermittlung wird seit Jahrzehnten die Multiple Lineare Regression für das Vergleichsverfahren eingesetzt /Ziegenbein 1977/, /Pelzer 1978/. Die beschreibenden Merkmale einer Immobilie (z. B. Wohnfläche oder Bodenrichtwert) erklären deren Kaufpreis. Die Analyse basiert auf einer Ausgleichung nach vermittelnden Beobachtungen. Daraus ergibt sich das folgende funktionale Modell (Gl. (1)):

$$\mathbf{y} = \mathbf{X}\mathbf{b} + \mathbf{e}. \quad (1)$$

Die Zielgröße \mathbf{y} (oftmals Kaufpreis pro Flächeneinheit) wird durch eine Linearkombination von Einflussgrößen \mathbf{X} und den unbekanntem Regressionskoeffizienten \mathbf{b} beschrieben. In der Praxis der Immobilienbewertung werden die unbekanntem Regressionskoeffizienten mithilfe der Methode der kleinsten Quadrate geschätzt /Fahrmeir et al. 2009/, /Koch 1997/. Die Residuen \mathbf{e} entsprechen den Differenzen zwischen dem Modell und den Beobachtungen, die aufgrund der Unvollkommenheit zwischen dem Modell und der Realität entstehen. Für eine korrekte Schätzung der Regressionskoeffizienten müssen die Residuen der Normalverteilung mit dem Mittelwert 0

und der Varianz s^2 folgen. Die Autoren verweisen auf die Fachliteratur, z. B. /Fahrmeir et al. 2009/ oder /Urban & Mayerl 2011/, für eine ausführlichere Diskussion der Regressionsanalyse.

Nichtlineare Zusammenhänge werden in der praktischen Immobilienbewertung oftmals nicht modelliert. Der Übergang auf eine nichtlineare Regressionsmodellierung scheitert an dem Vorwissen über quadratisch wirkende Einflussgrößen und Wechselwirkungen zwischen Einflussgrößen: Oftmals fehlen in der praktischen Anwendung Zeit und Ressourcen, um die aufwendigere nichtlineare Modellierung durchzuführen. Die Forderung nach einer AVM wird zunehmend größer. Praktische Ansätze zum Umgang mit Nichtlinearitäten in der MLR ist die Transformation von Einflussgrößen mit dem Exponenten bzw. dem Logarithmus oder das Beschneiden der Daten. In der Praxis wird nicht darauf geachtet, ob diese Transformation der Größen physikalisch sinnvoll ist (z. B. zunehmender Einfluss oder abnehmender Einfluss der Einflussgröße). Alternativ werden Daten auf einen kleineren Bereich beschnitten, in dem näherungsweise ein linearer Zusammenhang vermutet werden kann – dies ist jedoch mit einem Datenverlust der oftmals geringen Stichprobenanzahl verbunden.

3.1.2 Künstliche Neuronale Netze (KNN)

Künstliche Neuronale Netze (KNN) gehören zu den etablierten Verfahren aus dem Bereich des maschinellen Lernens. Lernen in diesem Sinne heißt, den Zusammenhang zwischen Einflussgrößen \mathbf{x} und Zielgrößen \mathbf{y} infolge einer Modellwahl und der anschließenden Adaption der unbekanntem Modellparameter \mathbf{w} zu bestimmen. Die Adaption findet im Zuge einer Schätzung auf Basis von zugeordneten Wertepaaren $(x, y)_t$ statt. Die Information bezüglich des funktionalen Zusammenhangs zwischen Einfluss- und Zielgrößen ist aufgrund der Endlichkeit der empirischen Datenreihen beschränkt. Aufgrund des Induktion-Prinzips der statistischen Lerntheorie wird deshalb anstatt der „wahren“ Risikofunktion, die der unzugänglichen bedingten Wahrscheinlichkeit $P(\mathbf{y} | \mathbf{x})$ bedarf, das empirische Risiko im Zuge der Schätzung minimiert /Vapnik 1999/. Inwieweit dieses empirische Modell dem „wahren“ Modell entspricht, lässt sich aus einem unabhängigen Testdatensatz folgern. Durch die Übertragung des bestimmten Modells auf einen unabhängigen

Datensatz (aus derselben Grundgesamtheit) lässt sich eine Aussage über die Prädiktions- bzw. Generalisierungsfähigkeit eines Modells ableiten.

Eine kurze Beschreibung der Funktionsweise von KNN wird im Folgenden gegeben; für nähere Informationen siehe /Heunecke et al. 2013/. Der funktionale Zusammenhang eines KNNs mit einer verdeckten Schicht m ist in Gl. (2) und schematisch in Abb. 1 gegeben. Auf Basis der Werte von L Einflussgrößen $x_l(t)$, denen l Knoten ($l = 1, \dots, L$) in der Eingangsschicht zugeordnet sind, und initialen Modellparametern $w_0 = [w_{m,l,0}; w_{n,m,0}]$ werden die N Zielgrößen $\hat{y}_n(t)$ ($n = 1, \dots, N$) der Ausgangsschicht berechnet. Die Aktivierungsfunktion φ ist die Basisfunktion der KNN /Haykin 1999/; t entspricht dem Datenpaarindex der T Trainingsdaten. Die berechnete Zielgröße $\hat{y}_n(t)$ wird mit der beobachteten Zielgröße $y_n(t)$ abgeglichen. Die Abweichung $e_n(t)$ wird in jedem Iterationsschritt i durch das Netz zurück propagiert, um die Parameter w_i so anzupassen, dass der totale Fehler ε_i aus Gl. (3) minimiert wird.

$$e_{n,i}(t) = y_n(t) - \hat{y}_{n,i}(t) = y_n(t) - f_n(\mathbf{w}_i, \mathbf{x}(t)) \\ = y_n(t) - \varphi^{(n)} \left(\sum_m w_{nm,i} \varphi^{(m)} \left(\sum_l w_{ml,i} x_l(t) \right) \right), \quad (2)$$

$$\varepsilon_i(t) = \frac{1}{2} \sum_n e_{n,i}^2(t). \quad (3)$$

Die Anzahl der Knoten in der verdeckten Schicht m sowie die verwendeten Aktivierungsfunktionen φ entscheiden über die Komplexität des Modells. Festlegungen bezüglich der Modellstruktur und der Aktivierungsfunktion können anhand des universellen Approximationstheorems /Hornik 1989/ getroffen werden. Dieses besagt, dass ein KNN mit nur einer verdeckten Schicht jede stetige Funktion beliebig genau approximieren kann, wenn die Aktivierung der Knoten in dieser Schicht mit einer sigmoidalen Funktion und die der Knoten in der Ausgangsschicht mit einer linearen Funktion erfolgt.

Die Wahl der optimalen Modellkomplexität bzw. die Festlegung der benötigten Knoten in der verdeckten Schicht wird im Zuge einer Modellselektion getroffen. Das Ziel dieser ist es, ein Modell zu erzeugen, das eine gute Prädiktion bzw. Generalisierung ermöglicht. Diese Fähigkeit ist beeinflusst durch drei Faktoren /Haykin 1999/:

1. die Trainingsdatenmenge und deren Repräsentativität,
2. die KNN-Modellstruktur und
3. die physikalische Komplexität des Systems.

Der Zusammenhang zwischen den ersten beiden Punkten zeigt sich bereits in Widrows Heuristik in Gl. (4) /Heunecke et al. 2013, S. 442/, die für Klassifizierungsaufgaben hergeleitet wurde. Diese gibt an, wie viele Parameter N_w auf Basis der zur Verfügung stehenden Trainingsmenge T unter einer angestrebten Prädiktionsabweichung e_{target} sinnvoll approximiert werden können und dient als Grenze für die Ableitung der maximal verwendbaren verdeckten Knoten.

$$T = \frac{N_w}{e_{\text{target}}}. \quad (4)$$

Fehlt die verdeckte Schicht m , so gehen KNN bei einer linearen Aktivierung der Eingangsknoten ($\varphi^{(n)} = 1$) in die lineare Regression der Form $\hat{y} = \sum_l w_{nl} x_l(t)$ über. Diese Struktur ist äquivalent zu

Gl. (1). KNN können deshalb als nichtlineare Erweiterung der Regression verstanden werden. Anhand der Reihenentwicklung der tanh-Aktivierungsfunktion, die in diesem Beitrag in der verdeckten Schicht verwendet wird, lässt sich zeigen, dass die linearen Anteile ebenfalls in einem KNN mit tanh-Aktivierung abgebildet sind (Gl. (5)). Bei a und b handelt es sich um zu wählende Konstanten, v entspricht dem Knoteneingang. Das nichtlineare Näherungsmodell ermöglicht einen besseren Einblick aufgrund der gruppierten Struktur der Nichtlinearität:

$$\varphi_{\text{tanh}} \left(\frac{v}{2} \right) = a \left[\frac{1}{2} (b v) - \frac{1}{24} (b v)^3 + \frac{1}{240} (b v)^5 + \dots \right]. \quad (5)$$

Ein Unterschied zur MLR besteht in den eingesetzten Verfahren zur Schätzung der unbekannt Parameter w . Die Regressionsparameter können im linearen Modell mittels Ausgleichung nach der Methode der kleinsten Quadrate in analytisch geschlossener Form geschätzt werden. Aufgrund der nichtlinearen Approximation bei KNN entsteht eine nicht-konvexe Fehlerfläche, welche eine iterative Schätzung erfordert. Je nach gewählten Initialwerten der Parameter w_0 besteht dabei die Gefahr, ein lokales anstelle des globalen Minimums zu erreichen. Die Optimierung kann nach verschiedenen Optimierungsverfahren erfolgen, z. B. Levenberg-Marquardt /Marquardt 1963/ (siehe Gl. (6)). Die Minimierung mittels Levenberg-Marquardt beinhaltet neben der Jacobi-Matrix J und dem Fehlerterm e einen Regularisierungsparameter λ , der einen Wechsel zwischen einem Gradientenverfahren und einer quadratischen Optimierung ermöglicht und damit schnellere Konvergenz gewährleistet. Vermindert sich der Fehler ε zwischen zwei aufeinanderfolgenden Iterationsschritten, wird der Regularisierungsparameter vermindert ($\lambda = \frac{\lambda}{\alpha}$). Das hat zur Folge, dass der quadratische Anteil zunimmt und der Algorithmus schneller konvergiert.

$$w_{i+1} = w_i - (J^T J + \lambda I)^{-1} J^T e. \quad (6)$$

3.2 Gütekriterien

Für die Beurteilung der Leistungsfähigkeit und den Vergleich der vorgestellten Methoden können verschiedene Gütekriterien herangezogen werden. Die Entscheidung fiel auf die nachfolgend aufgeführten Maße (siehe Gl. (7) bis (10)):

- Der **Root Mean Square Error (RMSE)** ist das gängige Gütekriterium für die MLR sowie für KNN.
- Der **mittlere absolute Fehler** (Mean Absolute Error – **MAE**) ist resistenter in Bezug auf Ausreißer.
- Der MAE kann auch als prozentualer Anteil ausgedrückt werden: **Mean Absolute Percentage Error (MAPE)**.
- Ein Streumaß des MAPE ist der **Fehler unter 5 %, EB5** (Errors Below 5 %), der die Anzahl relativer Abweichungen kleiner 5 % quantifiziert. Die 5 % richten sich nach der tolerierbaren Schätzfehlergrenze vieler Investoren /Nguyen & Cripps 2001/. Das Modell adaptiert sich besser an die tatsächlichen Zielgrößen, wenn viele relative Abweichungen kleiner als 5 % sind.

Eine gute Schätzung ist erzielt, wenn RMSE und MAE bzw. MAPE klein sind und der EB5 groß ist.

$$RMSE = \sqrt{\frac{\sum_{t=1}^T (y_t - \hat{y}_t)^2}{T}}; \quad (7)$$

$$MAE = \frac{\sum_{t=1}^T |y_t - \hat{y}_t|}{T}; \quad (8)$$

$$MAPE = \frac{\sum_{t=1}^T \frac{|y_t - \hat{y}_t|}{y_t}}{T}; \quad (9)$$

$$EB5 = \frac{\text{count}_t \left(\frac{|y_t - \hat{y}_t|}{y_t} < 0,05 \right)}{T}. \quad (10)$$

Das oftmals in der Wertermittlung eingesetzte Bestimmtheitsmaß R^2 ist als Gütekriterium beim Vergleich unterschiedlicher Modelle ungeeignet, da es sowohl von der Anzahl der Einflussgrößen als auch von der Anzahl der Daten abhängt /Stoetzer 2017, S. 219/. Unterschiedliche Modelle sind mit dem Bestimmtheitsmaß nur vergleichbar, wenn die Modelle dieselbe Zielgröße und dieselbe Zahl an Einflussgrößen und eine Konstante umfassen /Fahrmeir 2009, S. 99/. Die Praxis nutzt das Bestimmtheitsmaß aufgrund der einfachen Interpretierbarkeit irrtümlich dennoch, um eine Aussage zum Vergleich verschiedener Modelle (unterschiedliche Ziel- und Einflussgrößen) zu treffen, da R^2 den Anteil der Streuung misst, die durch das Modell erklärt wird /Soot et al. 2018/, obwohl u. a. /Goldberg 1991, S. 177 ff./ oder auch /Fahrmeir 2009, S. 99/ aufzeigen, dass es für Modellvergleiche ungeeignet ist. Auch bezüglich einer Entscheidung über die Kombination der Einflussgrößen ist das Bestimmtheitsmaß nur sehr beschränkt nutzbar. Mit der Zunahme weiterer Einflussgrößen verteilt sich der Restfehler auf alle Parameter. Somit kann durch eine Überparametrisierung ein deutlich höheres R^2 erzielt werden, welches allerdings nicht tatsächlich einen besseren Erklärungsgehalt haben muss, sondern rein mathematisch bedingt ist. Ein Vergleich von Bestimmtheitsmaßen zur Prüfung der Stärke einer Hypothese ist ebenfalls nicht geeignet /Soot et al. 2018/.

3.3 Versuchsdesign

Ziel dieses Beitrags ist der empirische Vergleich der Leistungsfähigkeit der MLR und der KNN in Aufgaben der Wertermittlung hinsichtlich der Modellierung der Nichtlinearitäten. Um die Vergleichbarkeit der beiden Methoden herzustellen, müssen dieselben Präprozessierungen des Datenmaterials für die MLR sowie für KNN durchgeführt werden. Aufgrund der speziellen Vorgehensweise bei der Modellierung mittels KNN ist der Versuchsaufbau maßgeblich getriggert durch die KNN.

Eine Aussage über die Güte der KNN-Modellierung im Anschluss an das Training der unbekannt Parameter \mathbf{w} wird auf Basis eines unabhängigen Testdatensatzes getroffen. Deswegen dürfen die Testdaten an der Schätzung nicht teilnehmen und müssen vor dem Training beiseitegelegt werden. Eine Aufspaltung des verfügbaren Datenmaterials in Trainings- und Testdaten wird meist in einem ähnlichen Verhältnis wie 8 : 2 /Heunecke 2013/ vorgenommen. Die

Aufspaltung des Datensatzes wird auch für die Berechnung der MLR vollzogen. Das heißt: Die Schätzung der MLR erfolgt auf Basis der Trainingsdaten und die Beurteilung der Leistungsfähigkeit der Methode basiert ebenfalls auf den unabhängigen Testdaten. Die nach dem Zufallsprinzip gezogene Test- bzw. Trainingsdatenmenge beeinflusst vor allem bei geringen Datenmengen die Prädiktionsfähigkeit des KNN maßgeblich. Um aussagekräftige Ergebnisse zu erhalten, werden die Trainingsdaten n -mal (z. B. $n = 100$) randomisiert aus der Grundgesamtheit gezogen und die Modellparameter geschätzt. Die MLR wird ebenfalls für die n Realisierungen der Trainingsdaten berechnet.

Aufgrund der Nichtlinearität des KNN-Modells werden Näherungswerte für die Modellparameter \mathbf{w} benötigt. Um keine Entscheidung auf Basis einer lokalen Lösung zu treffen, werden die Initialparameter \mathbf{w}_0 für jedes Paar von Trainings- und Testdaten neu initialisiert. Von den n Realisierungen werden Mittelwerte und Standardabweichungen der Gütekriterien (Gln. (7) – (10)) gebildet, um eine fundierte Entscheidungsbasis für die Beurteilung der Leistungsfähigkeit von KNN sowie der MLR zu erzeugen.

Die MLR benötigt keine Festlegung heuristischer Parameter. Für die Modellierung mittels KNN ist die Wahl des Regularisierungsparameters λ erforderlich. Dieser ermöglicht eine beschleunigte Konvergenz bei der Minimierung der Fehlerfunktion. Der initiale Regularisierungsparameter λ_0 und der Adaptionfaktor $d\lambda$ werden in Anlehnung an /Haykin 1999/ mit 0,01 und 1,5 gewählt.

Ob bzw. wann ein Lernprozess abgeschlossen ist, hängt von der Wahl des Konvergenzkriteriums ab. Als Kriterium wird die Anzahl der benötigten Iterationen vorgegeben. Dafür wird für jedes Modell vor dem Training eine Analyse des RMSE (Gl. (7)) pro Iterationsschritt durchgeführt und eine ideale Anzahl an Iterationen bestimmt.

Die Knotenanzahl in der verdeckten Schicht wird im Zuge der Modellselektion mittels Kreuzvalidierung festgelegt. Dafür wird der Trainingsdatensatz in n gleiche Teile aufgespalten; $n - 1$ Teile werden für das Training und der n -te Teil für die Validierung verwendet. In den Untersuchungen aus diesem Beitrag wurde – in Anlehnung an /James et al. 2019/ – hierfür $n = 5$ gewählt. Das Ergebnis der Kreuzvalidierung ist der Mittelwert aller n Realisierungen für eine bestimmte Knotenanzahl in der verdeckten Schicht. Werden die mittleren Fehler des Validierungsdatensatzes für die einzelnen Modellstrukturen verglichen, so spiegelt die Struktur mit dem geringsten mittleren Validierungsfehler die optimale Knotenanzahl wider. Um ebenfalls keine Entscheidung auf einer lokalen Lösung zu treffen, wird die 5-fache Kreuzvalidierung für jeweils 10 unterschiedliche Parameterinitialisierungen durchgeführt. Die Mittelwerte des RMSE (Gl. (7)) der Trainings- sowie Validierungsdaten werden pro Modellstruktur gebildet und den Ergebnissen der einzelnen Strukturen gegenübergestellt. Als Gesamtknoten-Obergrenze wird auf Basis der Daumenregel von Widrow (Gl. (4)) eine Parameteranzahl N_w bestimmt, die eine Prädiktionsabweichung e_{target} von 5 % für eine bestimmte Datenmenge T zulässt. Die 5 % wurden ebenfalls in Anlehnung an die tolerierbare Schätzfehlergrenze vieler Investoren /Nguyen & Cripps 2001/ gewählt.

4 BESCHREIBUNG DER STICHPROBEN

Im Rahmen der Analyse werden zwei Stichproben untersucht, für die eine Modellierung mit KNN einen Mehrwert gegenüber der klassischen Untersuchung mit MLR vermuten lässt. Die Datensätze sollen heterogen sein (Variationen in den Stichproben) und keine Ausreißer aufweisen. Für die Analyse werden die Daten der niedersächsischen Kaufpreissammlung – also reale Transaktionsabschlüsse – mit den weiteren in der Datenbank gespeicherten Informationen verwendet. Es werden zwei Datensätze untersucht, bei denen die MLR an ihre analytischen Grenzen gelangt:

- Aggregation vieler räumlicher Teilmärkte: Liegenschaftszinssätze in einer landesweiten Auswertung für Niedersachsen.
- Aggregation mehrerer sachlicher Teilmärkte: Vergleichsfaktoren für die Stadt Hannover im Teilmarkt der Einfamilienhäuser (freistehend, Doppelhaushälften und Reihenmittel-/Reihenendhäuser) gemeinsam mit hochpreisigen Objekten (Villen).

Beim ersten Datensatz handelt es sich um die landesweite Ableitung von Liegenschaftszinssätzen im Teilmarkt der Mehrfamilienhäuser (Abb. 2). Zielgröße ist der Liegenschaftszinssatz, der im Ertragswertverfahren zur Ableitung des Ertragswerts genutzt wird. Regelmäßig scheitern lokale Auswertungen (ein räumlicher Teilmarkt) lokaler Liegenschaftszinssätze an zu kleinen oder inhomogenen Datenmengen. Liegenschaftszinssätze für Mehrfamilienhäuser werden objektbezogen aus den Einflussgrößen Wohnfläche, Restnutzungsdauer und Reinertrag abgeleitet (Umkehr des Ertragswertverfahrens und iterative Lösung). Für jedes Mehrfamilienhaus, für das ein Kaufpreis sowie die genannten Einflussgrößen vorliegen, kann der Liegenschaftszinssatz abgeleitet werden.

Um die Abhängigkeiten des Liegenschaftszinssatzes zu modellieren, wird in der Praxis nur teilweise die

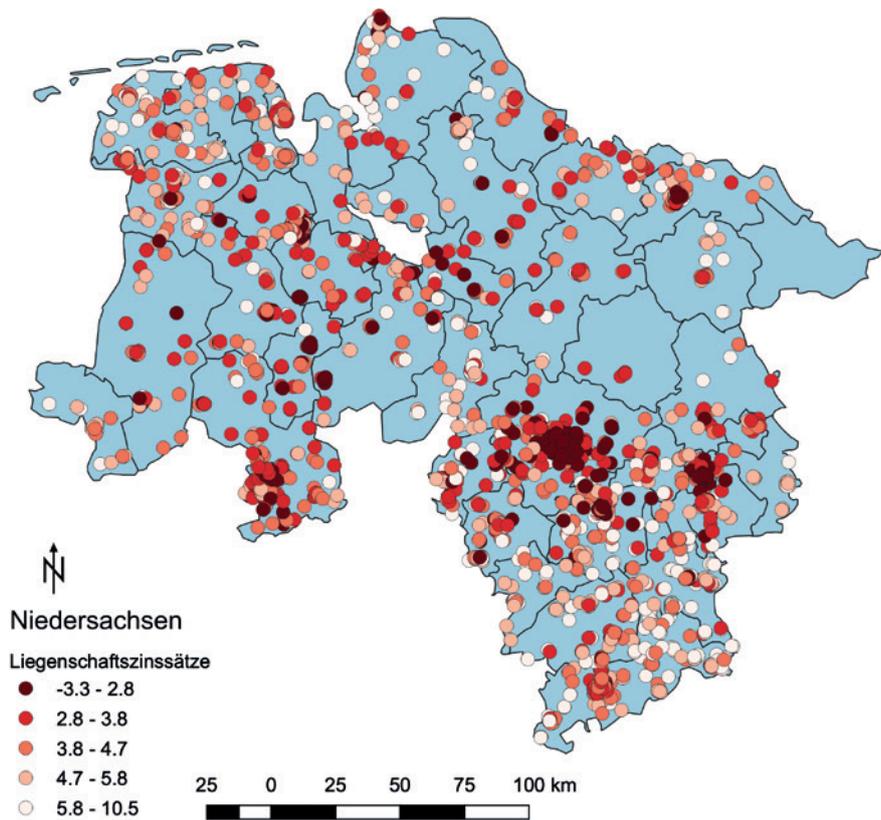


Abb. 2 | Übersicht der verwendeten Kauffälle von Mehrfamilienhäusern in Niedersachsen (2014–2018)

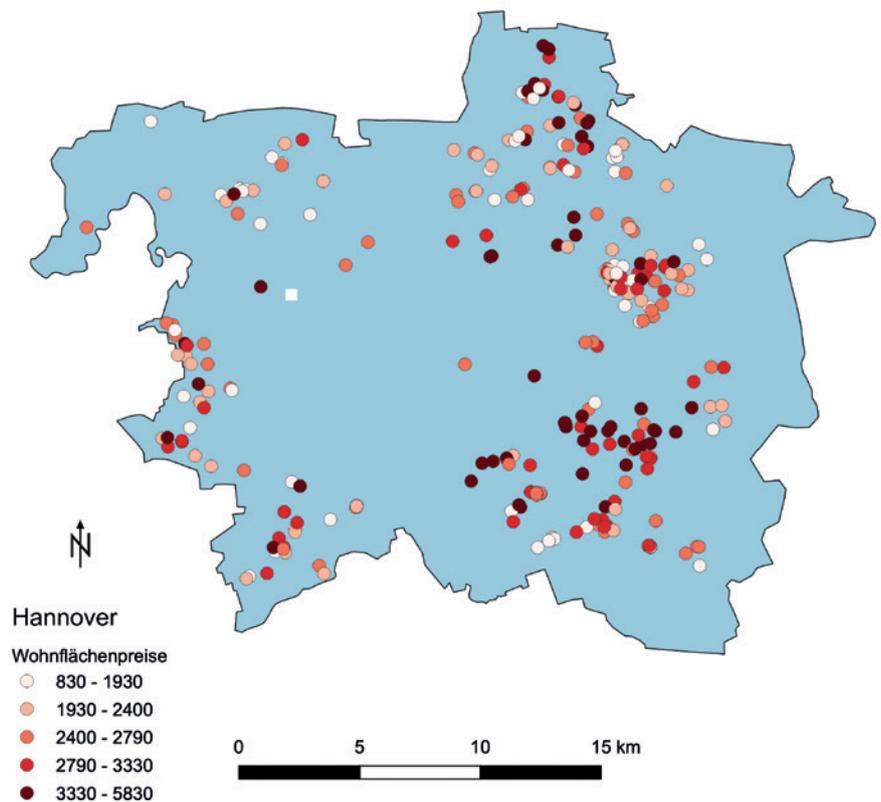


Abb. 3 | Übersicht der verwendeten Kauffälle für die Ableitung der Vergleichsfaktoren (hier: Wohnflächenpreise) des räumlichen Teilmarkts Einfamilienhäuser in Hannover (2014–2017)

MLR verwendet. Bei der Auswertung der Abhängigkeiten bedarf es nichtlinearer Modelle, was in der Praxis oftmals umgangen wird. Viele Gutachterausschüsse stellen lediglich die Darstellung von Mittelwert und Median der Liegenschaftszinssätze je Teilmarkt bereit. Für die verbleibenden Gutachterausschüsse, die eine MLR rechnen, um Einflüsse auf den Liegenschaftszinssatz abzuleiten, werden Strategien, wie die Beschneidung der Stichprobe oder die Akzeptanz geringer Bestimmtheitsmaße, angewendet. Daher wird vermutet, dass sich dieser Datensatz für die Auswertung mit KNN gut eignet.

Der zweite Datensatz deckt den gesamten Teilmarkt der Einfamilienhäuser in Hannover ab, für den normalerweise gesonderte Analysen durchgeführt werden (Abb. 3). Aufgrund der Stichprobengröße (Zusammenfassung mehrerer sachlicher Teilmärkte) ist dies eine Gesamtauswertung. Räumliche Disparitäten sind verursacht durch die unterschiedlichen Lagen in der Großstadt: In innerstädtischen Lagen befinden sich nur wenige Einfamilienhäuser; diese liegen zumeist am Rand der Stadt.

Da für die Auswertungen ausreißerfreie Daten verwendet werden sollen, muss im Vorgang der Analyse eine Ausreißerbereinigung durchgeführt werden. Die Ausreißerbereinigung der Datensätze erfolgt zunächst pragmatisch aus dem in der Wertermittlung verwendeten Ansatz der Bereinigung über die Cook-Distanz /Soot et al. 2018/. Die Datensätze werden in einem ersten Schritt mit einer klassischen multivariaten Regression analysiert und Kauffälle, die eine auffällig hohe Cook-Distanz ($> 4/n$) hatten, ausgeschlossen. Die daraus resultierenden Datensätze werden für die weitere Analyse verwendet.

4.1 Räumlicher Teilmarkt Niedersachsen für die Ermittlung von Liegenschaftszinssätzen

Bei der genutzten Datenstichprobe handelt es sich um Liegenschaftszinssätze aus Niedersachsen für den Teilmarkt der Mehrfamilienhäuser. Insgesamt waren 3784 Kauffälle in der Kaufpreissammlung erfasst, für die eine Ableitung des Liegenschaftszinssatzes möglich war. Hiervon können 3343 Kauffälle genutzt werden, deren

Einträge vollständig und plausibel sind (z.B. ohne Kauffälle auf Inseln oder außergewöhnlich kurzer Restnutzungsdauer (< 15 Jahre)). Nach der unter Kapitel 4 beschriebenen Ausreißerbereinigung verbleiben $n = 2917$ Kauffälle im Datensatz, die über die gesamte Landesfläche streuen (Abb. 2).

Die deskriptive Statistik der verwendeten Daten ist in Tab. 1 dargestellt. Die Daten weisen in einigen Größen teilweise sehr große Abweichungen auf. Dies ist darauf zurückzuführen, dass einzelne Objekte als größere Wohnanlagen gehandelt werden. Da die Objekte aber in sich zu plausiblen Ergebnissen führen, können diese in der Auswertung mitverwendet werden. Die Parameter, in denen die

	Minimum	Maximum	Mittelwert	Median	Verteilung
Liegenschaftszinssatz	-3,33 %	10,48 %	8,4 %	6 %	
Gesamtkaufpreis	45 000 €	24 444 781 €	579 971 €	330 000 €	
Wohnfläche	120 m²	14 090 m²	556 m²	368 m²	
Restnutzungsdauer	15 a	70 a	30,8 a	28 a	
Anzahl Wohnungen	2	222	8,3	6	
Baujahr	1648	2018	1947	1957	
Reinertrag	3 239 €/a	956 648 €/a	28 777 €/a	18 126 €/a	
Bodenrichtwert	8 €/m²	1 550 €/m²	143 €/m²	100 €/m²	
Kaufjahr	2014	2018	2016	2016	
Regionstyp	1	6	-	-	

Tab. 1 | Darstellung der deskriptiven Statistik der verwendeten Kauffälle von Mehrfamilienhäusern in Niedersachsen (2014-2018)

Kauffälle wesentlich abweichen, werden in den genutzten Modellen nicht als Einflussgrößen verwendet.

4.2 Sachlicher Teilmarkt der Vergleichsfaktoren von Einfamilienhäusern in Hannover

Für den Teilmarkt der Einfamilienhäuser inkl. Villen konnte im räumlichen Teilmarkt Hannover eine Stichprobe von 310 Kauffällen selektiert werden. Die genutzte Datenstichprobe aus dem Teilmarkt der Einfamilienhäuser inkl. Villen enthält nach der unter Abschnitt 4 beschriebenen Ausreißerbereinigung 302 Kauffälle. Die deskriptive Statistik ist in Tab. 2 dargestellt.

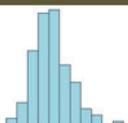
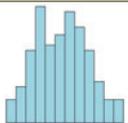
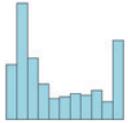
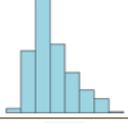
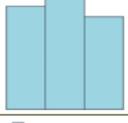
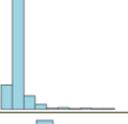
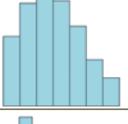
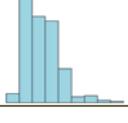
Für die Auswertung wurde ein Datensatz in einem Zeitraum von drei Jahren selektiert. Hierbei werden lediglich die nach dem Zweiten Weltkrieg erstellten Gebäude genutzt, um Besonderheiten der Bauweise der Altbauten auszuschließen. Die Verteilungen der Daten weisen keine Besonderheiten auf.

Um überprüfen zu können, ob der Datensatz Hannover die angenommene nichtlineare Modellkomplexität beinhaltet (siehe Abschnitt 5.2) und zur Modellierung mit KNN geeignet ist, wird der Datensatz auf Basis einer strukturerhaltenden Simulation vergrößert. Auch die Auswahl eines sachlichen Teilmarkts mit ausreichender Datenmenge wäre denkbar gewesen, hätte aber den Anforderungen, auch kleinere Teilmärkte auswerten zu können, widersprochen. Daher werden aus den Teilmärkten auswertbare Stichproben generiert (Abb. 4).

Da für den sachlichen Teilmarkt der Einfamilienhäuser für eine Auswertung mit KNN in lokalen Märkten eine zu geringe Datenmenge vorliegt, erfolgt in einem ersten Schritt eine sachlich-teilmarktübergreifende Aggregation der Daten (gemeinsame Auswertung der verschiedenen Einfamilienhaustypen). Dies hat den Vorteil, dass anteilig kleinere sachliche Teilmärkte in der Stichprobe mit ausgewertet werden können, die als einzelner sachlicher Teilmarkt für eine Auswertung zu geringen Stichprobenumfang aufweisen. Durch die Aggregation entsteht eine genügend große Stichprobe einen zur Auswertung in KNN, die aber den Nachteil hat, sehr heterogen zu sein. Um eine homogene und genügend große Stichprobe zu generieren, wird in einem nächsten

Schritt ein hierarchisches Clusterverfahren zur Aufteilung in homogene Teil-Stichproben eingesetzt.

Die Clustering erfolgt nach der Methode Ward mit den Einflussgrößen Wohnflächenpreis, Wohnfläche, Bodenrichtwert, Baujahr, Grundstücksfläche und Restnutzungsdauer (den für den sachlichen Teilmarkt typischen Ziel- und Einflussgrößen; in Abb. 4 sind Kauffälle mit ähnlichen Einflussgrößen durch gleiche Farben visualisiert). Das Kaufdatum beeinflusst aufgrund der starken konjunkturellen Änderung im betrachteten Zeitraum die Clustering so stark, dass nur zeitlich geclustert werden würde: Daher wird auf die zeitliche Variable bei der Clustering verzichtet. Standardstufe und Modernisierungsgrad sind nur unvollständig besetzt; auf die Nutzung imputierter Daten wird verzichtet (s. unten). Stattdessen werden das Baujahr und die Restnutzungsdauer verwendet (hier liegt eine vollständige Belegung vor), die stark korrelieren, aber etwas weniger Einfluss auf die Zielgröße haben.

	Minimum	Maximum	Mittelwert	Median	Verteilung
Wohnflächenpreis (Vergleichsfaktor)	562 €/m ²	5 904 €/m ²	2 668 €/m ²	2 584 €/m ²	
Wohnfläche	80 m ²	200 m ²	139 m ²	140 m ²	
Restnutzungsdauer	15 a	70 a	39 a	32 a	
Baujahr	1945	2017	1979	1972	
Bodenrichtwert	105 €/m ²	460 €/m ²	259 €/m ²	250 €/m ²	
Kaufdatum	2014	2017	2016	2016	
Modernisierungsgrad	0	20	4	4	
Standardstufe	1	4,5	2,7	2,5	
Grundstücksgröße	182 m ²	1 718 m ²	545 m ²	502 m ²	

Tab. 2 | Darstellung der deskriptiven Statistik der verwendeten Kauffälle für die Ableitung der Vergleichsfaktoren des räumlichen Teilmarkts Einfamilienhäuser in Hannover (2014–2017)

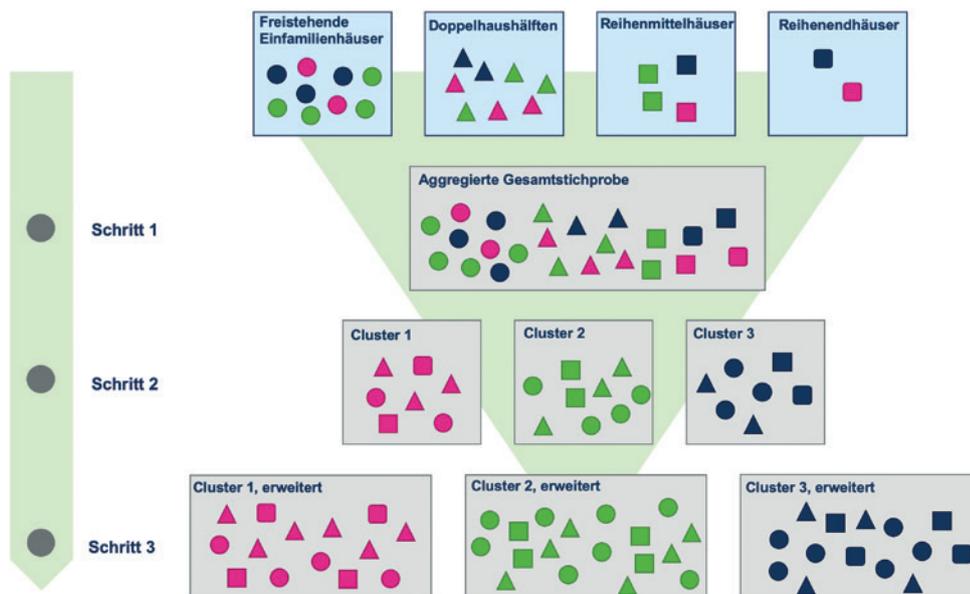


Abb. 4 | Vorgehensweise zur Bildung von Stichproben

Die Methode nach Ward führt zu homogenen Clustern, da sie immer die beiden Cluster fusioniert, die die kleinste Varianzerhöhung im neuen Cluster erzeugt (Fehlerquadratsumme innerhalb der Cluster). Weiterführende Angaben zur Clusterung nach der Methode Ward sind in /Bortz & Schuster 2010/ zu finden. Aus dem Dendrogramm werden drei Cluster als optimal identifiziert: Diese entsprechen jedoch nicht den aggregierten sachlichen Teilmärkten. Die Clusterung wiederum reduziert die Datenmenge, erlaubt aufgrund der Homogenität in den Clustern allerdings die Simulation weiterer Datensätze und der Vergrößerung der Stichprobe, sodass diese mit KNN auswertbar sind.

Ausgehend von den drei gebildeten Clustern werden in einer strukturerhaltenden Simulation mittels Support Vector Regression (SVR) /Cherkassky & Mulier 1998/ zusätzliche neue, fiktive Daten generiert, die dem Ausgangsdatsatz des jeweiligen Clusters entsprechen. Die Support Vector Machine gehört ebenfalls zu den Lernmethoden und wurde ursprünglich zur Klassifizierung zweier Klassen entwickelt. Die Problemformulierung ermöglicht die Bestimmung der optimalen Trennlinie/-fläche (durch die Maximierung der Margin) zweier Klassen. Die Wahl dieser Methode für die Simulation ist dadurch begründet, dass die Spezifikation der Modellstruktur implizit mit der Minimierung der Parameter erfolgt und dadurch konträr zu den KNN ist. Wichtig dabei ist, dass die simulierten Zielgrößen nichtlinear prädiziert werden.

Grundsätzlich werden die einzelnen Einflussgrößen pro Cluster unabhängig voneinander gezogen. Einzige Ausnahme bilden die Wohnfläche und die Grundstücksfläche, die aufgrund ihres kausalen Zusammenhangs (Korrelation > 0,7) gemeinsam gezogen werden. Die SVR wird zuerst auf Basis der originalen Datenpaare pro Cluster geschätzt, um in weiterer Folge die Zielgröße in Abhängigkeit der gezogenen Einflussgrößen zu prädizieren. Die Verteilungen der simulierten Daten werden mit den originalen Daten abgeglichen und auf deren Gültigkeit anhand von Merkmalen wie Varianz und Schiefe überprüft. Entsprechen die simulierten Verteilungsmaße nicht den originalen, werden die heuristischen Parameter der SVR-

Modellierung adaptiert. Abschließend werden die simulierten Daten der drei Cluster zu einem teilmärktübergreifenden Datensatz vereint.

Es sei darauf hingewiesen, dass die Simulation nur zum Zwecke der Datenvervielfältigung angewandt wird, um das Verfahren der KNN evaluieren zu können (siehe Abschnitt 5.2). Im Rahmen dieser Arbeit wird nicht geprüft, inwieweit die simulierten Daten einer realen Stichprobe auf dem Immobilienmarkt entsprechen.

5 EMPIRISCHE UNTERSUCHUNG DER STICHPROBEN

Im folgenden Abschnitt erfolgt die Auswertung der zuvor beschriebenen Stichproben mit der klassischen MLR sowie mit KNN. Die beiden Methoden werden unter der in Abschnitt 3.3 spezifizierten Vorgehensweise berechnet und die Ergebnisse gegenübergestellt. Dabei wird untersucht, ob die Modellierung mit KNN gegenüber der MLR einen Mehrwert aufweist.

5.1 Ermittlung von Liegenschaftszinssätzen in Niedersachsen

Die Ableitung von Liegenschaftszinssätzen stellt Gutachterausschüsse insbesondere in kaufpreisarmen Lagen (regelmäßig ländliche Räume, da dort Immobilien zumeist eigengenutzt und nicht vermietet sind) vor Herausforderungen. Daher gibt es die Bestrebung einer landesweiten Auswertung. Diese erfolgt oftmals durch die etablierte MLR. Aufgrund der schwer zu modellierenden Nichtlinearitäten in derartigen Märkten scheitern diese Methoden bzw. liefern schlechte Ergebnisse. Liegenschaftszinssätze und das damit verbundene Investitionsrisiko sind landesweit heterogen und nur bedingt linear modellierbar. Damit bieten sie sich für eine Aggregation der räumlichen Teilmärkte an. Der Liegenschaftszinssatz aus Niedersachsen wird in zwei Varianten modelliert:

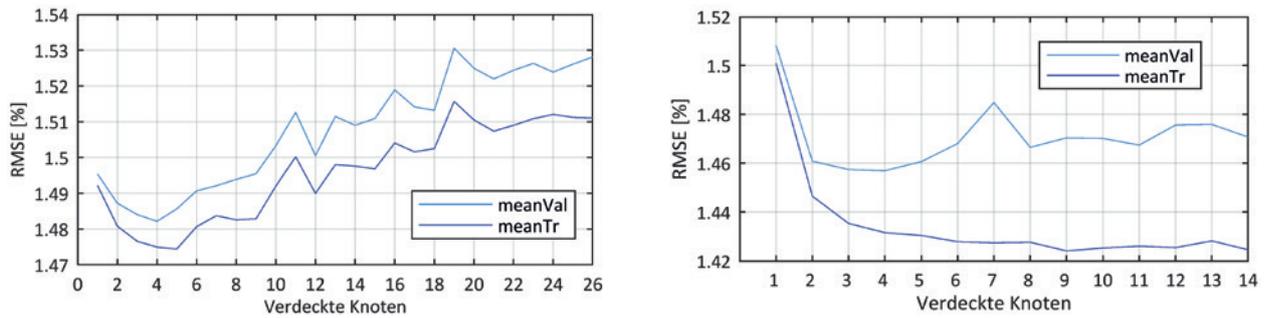


Abb. 5 | Modellselektion für Variante 1 (links) und Variante 2 (rechts) des Datensatzes Liegenschaftszinssätze in Niedersachsen; der mittlere Validierungsfehler (meanVal) wird dem mittleren Trainingsfehler (meanTr) pro Anzahl der verdeckten Knoten gegenübergestellt

■ In Variante 1 werden als Einflussgrößen der Bodenrichtwert, der Regionstyp und das Kaufjahr modelliert (entsprechend der Auswertung des Oberen Gutachterausschusses Niedersachsen 2019).

■ In einer erweiterten Modellierung, weiterhin als Variante 2 bezeichnet, werden zusätzlich die Restnutzungsdauer sowie Entfernungen zu Bahnhof, Einzelhandel, Schule und Arzt aufgenommen.

Der Datensatz beinhaltet 2917 verwendbare Datenpaare, die im Verhältnis 9:1 in Trainings- und Testdaten getrennt werden. Die Aufteilung in Trainings- und Testdaten erfolgt durch eine zufällige Ziehung; diese wird 100-mal durchgeführt (siehe Abschnitt 3.3).

Das Ergebnis der Modellselektion mittels Kreuzvalidierung für beide Varianten ist in Abb. 5 dargestellt. Die Werte sind Mittelwerte der 10 Parameterinitialisierungen. Die Modellselektion wird mit der maximalen verdeckten Knotenanzahl von 26 bzw. 14 (Variante 1 bzw. Variante 2) begrenzt, abgeleitet von der Daumenregel von

Methode	Mean (RMSE)	Mean (MAPE)	Mean (EB5)	Std (RMSE)	Std (MAPE)	Std (EB5)	KNN < MLR
MLR	1,5164 %	74,2 %	11,8 %	0,0754 %	33,9 %	1,7 %	89/100
KNN	1,4481 %	66,5 %	11,8 %	0,0700 %	28,9 %	1,7 %	

Tab. 3 | Statistik der Modellierungsergebnisse Variante 1 des Datensatzes Liegenschaftszinssätze in Niedersachsen

Methode	Mean (RMSE)	Mean (MAPE)	Mean (EB5)	Std (RMSE)	Std (MAPE)	Std (EB5)	KNN < MLR
MLR	1,5053 %	84,2 %	11,9 %	0,0668 %	41,2 %	1,6 %	96/100
KNN	1,4231 %	66,2 %	11,7 %	0,0614 %	26,8 %	1,7 %	

Tab. 4 | Statistik der Modellierungsergebnisse Variante 2 des Datensatzes Liegenschaftszinssätze in Niedersachsen

Widrow. Für beide Varianten führen vier verdeckte Knoten zu einem mittleren minimalen Validierungsfehler.

Die Modellselektion für Variante 2 weist einen typischen Verlauf des RMSE auf: Mit zunehmender Knotenanzahl nimmt der Trainingsfehler ab; der Validierungsfehler sinkt zu Beginn ebenfalls, fängt jedoch ab dem Zeitpunkt der Adaption des Rauschens zu steigen an und zeigt dadurch an, dass die Übertragbarkeit auf einen unabhängigen Datensatz – den Validierungsdatensatz – nicht mehr gegeben ist bzw. dass die Prädiktionsfähigkeit des KNN abnimmt. Die beste Generalisierungsfähigkeit des KNN ist bei minimalem Validierungsfehler erreicht.

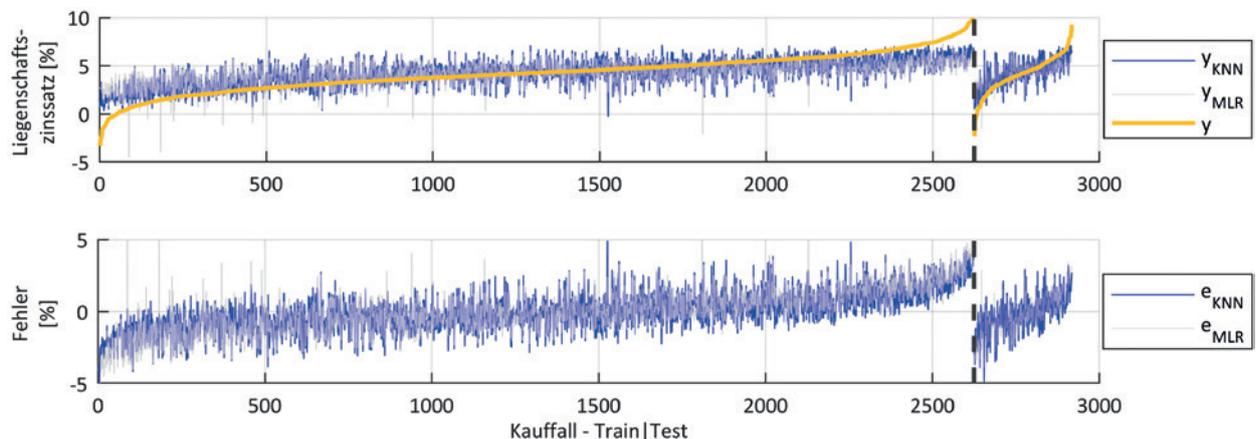


Abb. 6 | Vergleich der originalen Zielgrößen y (gelb) in aufsteigender Reihenfolge mit den Modellierungen mittels KNN (blau) und MLR (grau) sowie die entsprechenden Residuen e der beiden Methoden – Datensatz Liegenschaftszinssätze in Niedersachsen Modellierungs-Variante 2

Die Modellselektion für Variante 1 zeigt, dass mit zunehmender Knotenanzahl auch der Trainingsfehler steigt. Dies lässt auf eine unzureichende Beschreibung der Ausgangsgröße

Methode	Mean (RMSE)	Mean (MAPE)	Mean (EB5)	Std (RMSE)	Std (MAPE)	Std (EB5)	KNN < MLR
MLR	569,64 €/m ²	18,8 %	18,4 %	92,3 €/m ²	4,8 %	7,9 %	25/100
KNN	594,22 €/m ²	19,3 %	18,6 %	101,6 €/m ²	4,9 %	7,3 %	

Tab. 5 | Statistik der Modellierungsergebnisse der Einfamilienhäuser in Hannover

aus den gewählten Einflussgrößen schließen; es dominieren die systematischen Effekte, die durch Nichtberücksichtigung weiterer Einflussgrößen hervorgerufen werden, während die Approximation des Rauschens weiterhin von untergeordneter Bedeutung ist.

Die Ergebnisse auf Basis der zuvor bestimmten Netzstruktur sind in Tab. 3 und Tab. 4 dargestellt. Dabei handelt es sich um Mittelwerte und Standardabweichungen der Gütekriterien aus 100 Modellierungsdurchläufen. In jedem Modellierungsdurchlauf werden durch randomisiertes Ziehen Trainings- und Testdaten generiert. Ebenfalls werden die Startwerte der unbekanntenen Modellparameter jeweils randomisiert generiert. Die nichtlineare Modellierung mit KNN schneidet in 89 bzw. 96 von 100 Fällen besser ab als die lineare Modellierung mittels MLR. Die Entscheidung beruht auf einem geringeren RMSE- sowie auf einem geringeren MAPE-Mittelwert. Der mittlere RMSE der Testdaten ist für die KNN-Prozessierung im Vergleich zur MLR um rund 5 % vermindert. Werden die beiden Varianten miteinander verglichen, so wird die bessere Modelladaption mit den erweiterten Einflussgrößen der Variante 2 offensichtlich. Es zeigt sich bereits in der Modellselektion, dass die unzureichende Beschreibung der Zielgröße durch die gewählten Einflussgrößen in Variante 1 zu einer schlechteren Schätzung führt.

In Abb. 6 ist eine Beispielrealisierung der Modellierungsvariante 2 dargestellt. Die obere Grafik zeigt die Modellierungen mit KNN (blau) und MLR (grau) im Vergleich zu den Original-Zielgrößen (gelb). Die Daten werden aufsteigend nach den Original-Zielgrößen (Liegenschaftszinssatz) sortiert. Die untere Grafik beinhaltet die Residuen beider Methoden (ebenfalls sortiert nach Original-Zielgrößen). Die ersten 2624 Kauffälle wurden für das Training der KNN-Parameter verwendet. Auf Basis der letzten 293 Eingangswerte wurden die Zielgrößen mit dem trainierten KNN geschätzt und mit den originalen Werten der Zielgröße abgeglichen (rechts neben der vertikalen, gestrichelten Linie). Vor allem für kleine (0–200) und große (2400 – 2624) Zinssätze werden geringere Residuen mit der KNN-Modellierung erzielt.

Eine Einbeziehung der Landkreise sowie der Kaufjahre als kategoriale Einflussgrößen wurde untersucht und zunächst verworfen. Der Grund dafür ist die Steigerung der Dimensionalität von 8 auf 47 Eingangsknoten bei der Auswertung mit KNN. Bei gleichbleibender Modellstruktur (4 verdeckte Knoten) bedeutet das einen Anstieg der zu schätzenden Parameter von 41 auf 197. Eine derartige Modellvergrößerung führt dazu, dass die Trainingsdatenmenge von rund 2600 Datenpaaren zu gering ist, um diese Komplexität abzubilden.

5.2 Ermittlung von Vergleichsfaktoren für Einfamilienhäuser in Hannover

Die Wahl des Datensatzes Einfamilienhäuser in Hannover ist begründet mit der gemeinsamen Behandlung unterschiedlicher sachlicher Teilmärkte, wie Einfamilienhäuser und Villen, und die daraus entstehende Nichtlinearität bei der Ermittlung von Vergleichsfaktoren. Durch die Aggregation der Teilmärkte liegt eine genügend große Stichprobe für die Verwendung der MLR und der KNN vor. Da der sachliche Teilmarkt schon hinreichend untersucht wurde, sind die Einflussgrößen und die Modellvorstellung bekannt (z. B. /Soot et al. 2016/).

Die Zielgröße des zu modellierenden Systems ist der Wohnflächenpreis in €/m². Die gewählten Einflussgrößen sind Wohn-

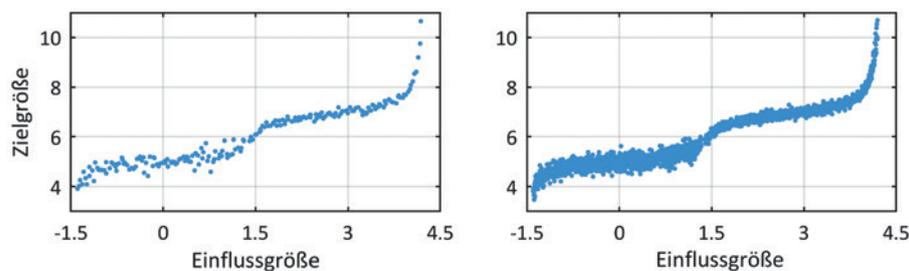


Abb. 7 | Theoretisches Beispiel (2 tan-Funktionen); 200 Datenpaare (links) und 2000 Datenpaare (rechts)

Methode	Mean (RMSE)	Mean (MAPE)	Mean (EB5)	Std (RMSE)	Std (MAPE)	Std (EB5)	KNN < MLR
MLR	0,36	4,5 %	66,8 %	0,11	0,6 %	7,2 %	43/100
KNN	0,34	4,3 %	65,3 %	0,10	0,8 %	11,2 %	

Tab. 6 | Statistik der Modellierungsergebnisse des theoretischen Beispiels mit 200 Datenpaaren

Methode	Mean (RMSE)	Mean (MAPE)	Mean (EB5)	Std (RMSE)	Std (MAPE)	Std (EB5)	KNN < MLR
MLR	0,35	4,3 %	69,3 %	0,03	0,2 %	2,3 %	100/100
KNN	0,18	2,5 %	86,8 %	0,02	0,2 %	2,6 %	

Tab. 7 | Statistik der Modellierungsergebnisse des theoretischen Beispiels mit 2000 Datenpaaren

fläche, Bodenrichtwert, Kaufdatum, Grundstücksfläche, Standardstufe und Modernisierungsgrad. Diese Einflussgrößen sind regelmäßig (die Gutachterausschüsse sind nach Baugesetzbuch (BauGB) und Immobilienwertermittlungsverordnung (ImmoWertV) verpflichtet, die Vergleichsfaktoren mindestens alle zwei Jahre abzuleiten) signifikant für diesen Teilmarkt (vgl. /Grundstücksmarktberichte Hameln-Hannover 2019/). Der untersuchte Datensatz beinhaltet 300 Datenpaare, wovon 89 fehlende Einträge aufweisen. Die Aufteilung in Trainings- und Testdaten erfolgt im Verhältnis 85 : 15. Die Auswertung der verbleibenden 211 Paare zeigt, dass die Modellierung mittels MLR zur besseren Prädiktion der Zielgrößen führt. Diese Schlussfolgerung stützt sich auf den Vergleich der Mittelwerte und Standardabweichungen der betrachteten Gütekriterien (vgl. Abschnitt 3.2) aus Tab. 5. Die Berechnung der Mittelwerte und Standardabweichungen resultiert aus der 100-maligen wiederholten und randomisierten Generierung von Trainings- und Testdatensätzen sowie der zufälligen Generierung der Startwerte für die unbekannt Parameter in analoger Vorgehensweise zum Abschnitt 3.3. Nur in 25 von 100 Fällen führen die mittels KNN prädizierten Zielgrößen zu niedrigeren RMSE- und MAPE-Werten.

Auch die Nutzbarmachung der lückenbehafteten 89 Datenpaare, indem der fehlende Eintrag der Standardstufe durch den Mittelwert ergänzt wird, verändert den Sachverhalt nicht und führt zu keiner neuen Erkenntnis. Daraus lässt sich schließen, dass die Datenmenge die Komplexität des Modells nicht wiedergibt.

Diese Schlussfolgerung soll durch einen zweidimensionalen Beispieldatensatz bestätigt werden. Zwei tan-Funktionen, überlagert mit unterschiedlichem Rauschen, werden in Anlehnung an die beiden sachlichen Teilmärkte der Stichprobe gewählt. Es werden daraus zwei Datensätze generiert, die sich nur in der Datenmenge unterscheiden (Abb. 7) und 200 bzw. 2000 Datenpaare beinhalten.

Für den Datensatz mit 200 Datenpaaren zeigt sich ein ähnliches Verhalten wie für die Originaldaten der Stichprobe Hannover. In 57 % der Fälle ist die lineare Regression

Methode	Mean (RMSE)	Mean (MAPE)	Mean (EB5)	Std (RMSE)	Std (MAPE)	Std (EB5)	KNN < MLR
MLR	546,41 €/m ²	18,6 %	15,0 %	9,1 €/m ²	0,4 %	0,8 %	30/30
KNN	447,85 €/m ²	12,0 %	33,8 %	14,6 €/m ²	0,6 %	2,5 %	

Tab. 8 | Statistik der Modellierungsergebnisse der simulierten Daten – Einfamilienhäuser in Hannover

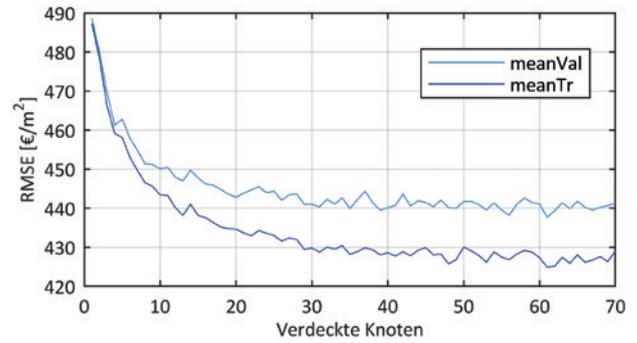


Abb. 8 | Modellselektion der simulierten Daten – Einfamilienhäuser in Hannover; der mittlere Validierungsfehler (meanVal) wird dem mittleren Trainingsfehler (meanTr) pro Anzahl der verdeckten Knoten gegenübergestellt

aufgrund des kleineren RMSE und des MAPE die zu bevorzugende Methode (Tab. 6). Die Daten können die Modellkomplexität nicht wiedergeben und das „einfachere“ Modell ist überlegen. Zwar liefert im Mittelwert das KNN die kleineren RMSE- und MAPE-Werte, bei Hinzuziehen der jeweiligen Standardabweichungen wird jedoch die Nichtsignifikanz dieses Unterschieds sehr deutlich.

Bei einer Verzehnfachung der Datenpaare zeigt sich, dass die Datenmenge für die Modellkomplexität der nichtlinearen Modellierung mit KNN ausreichend ist und diesen Zusammenhang in 100 % der Fälle wiedergibt (Tab. 7). Die Unterschiede zwischen den Mittelwerten der Gütekriterien, die aus der Anwendung der beiden Methoden resultieren, sind signifikant. KNN sind in diesem Fall die zu bevorzugende Methode; alle Gütekriterien bestätigen die verbesserte Prädiktionsfähigkeit der KNN.

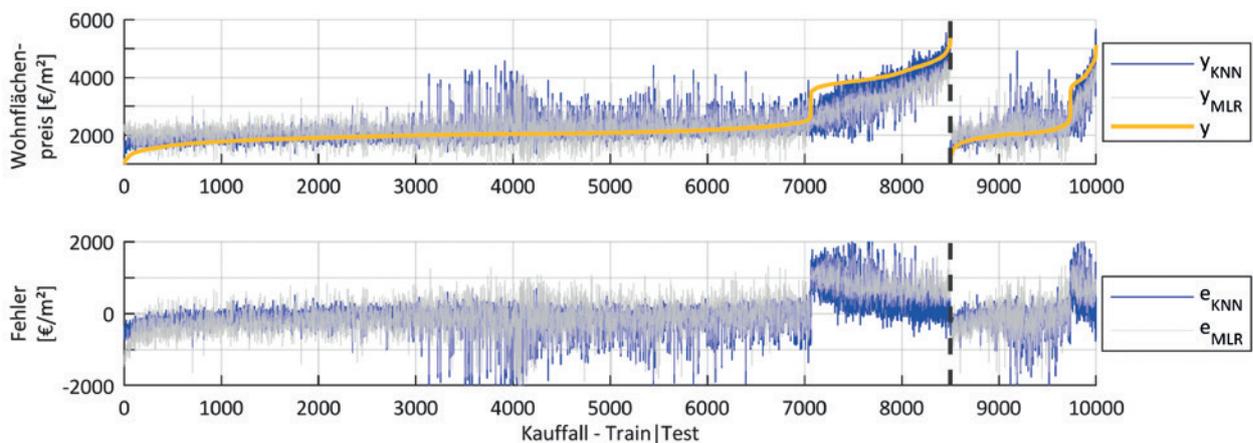


Abb. 9 | Vergleich der originalen Zielgrößen y (gelb) in aufsteigender Reihenfolge mit den Modellierungen mittels KNN (blau) und MLR (grau) sowie der entsprechenden Residuen e der beiden Methoden – Datensatz Einfamilienhäuser in Hannover

RIEGL Laserscanner für kleine UAVs

Selbst wenn die parametrische Form des Modells bekannt ist, wird die Modellkomplexität von der verfügbaren finiten Datenmenge mitbestimmt. Im Falle des originalen Einfamilienhaus-Datensatzes ermöglichen die vorhandenen Daten nur eine wenig komplexe (sprich lineare) Modellierung. Das KNN ist der MLR aufgrund der geringen Anzahl von Datensätzen unterlegen.

Um nun überprüfen zu können, ob der Datensatz Hannover die angenommene nichtlineare Modellkomplexität beinhaltet, wird der Datensatz daher auf Basis einer strukturerhaltenden Simulation vergrößert (dafür notwendige Methoden und Prozessierungen zur Erstellung dieses Simulationsdatensatzes sind in Abschnitt 4.2 näher beschrieben). Mit der rund 35-fach simulationsbasiert erhöhten Datenmenge wird nun die Auswertung mit beiden Methoden wiederholt durchgeführt. Zur Bestimmung der KNN-Modellstruktur für den simulierten Datensatz wird die 5-fache Kreuzvalidierung, wie in Abschnitt 3.3 näher erläutert, angewandt. Die KNN-Modellselektion in *Abb. 8* ergibt einen minimalen mittleren Validierungsfehler für 61 verdeckte Knoten. Damit ermöglicht diese Struktur die beste Übertragbarkeit auf unabhängige Testdaten (Generalisierung).

Für den Vergleich der MLR und der KNN werden 30 Realisierungen, basierend auf der zufälligen Ziehung von Trainings- und Testdaten, modelliert. Mit jedem neuen Datensatz von Trainings- und Testdaten werden die Parameter neu initialisiert. Die Mittelwerte und Standardabweichungen der Gütekriterien sind in *Tab. 8* aufgeführt. In 30 von 30 Fällen führt die nichtlineare KNN-Modellierung im Vergleich zur MLR zu einem signifikant geringeren mittleren RMSE und MAPE der Testdaten. Der mittlere RMSE der KNN-Modellierung ist im Vergleich zur MLR um 18 % vermindert. Auffällig ist die höhere Variation der KNN-Modellierung, die auf die Parameterinitialisierung sowie auf die größere Sensitivität hinsichtlich der Datenheterogenität zurückzuführen ist. Die Modellierung mit KNN ist insofern der MLR überlegen.

In *Abb. 9* ist eine Beispielrealisierung dargestellt. Die obere Grafik zeigt die Modellierungen mit KNN (blau) und MLR (grau) im Vergleich zu den Original-Zielgrößen (gelb); die untere Grafik präsentiert die entsprechenden Residuen. Die Daten werden wiederum aufsteigend nach den Original-Zielgrößen (Wohnflächenpreise) sortiert. Die ersten 8500 Kauffälle (Eingangswerte) werden für das Training der KNN-Parameter verwendet. Die letzten 1500 Kauffälle dienen der Qualitätsbeurteilung der beiden Modellierungen. Die Datenpaare von 0 bis 7000 beinhalten das Cluster 1 und 2, die Datenpaare 7000 bis 8500 entsprechen dem dritten Cluster. Die Testdaten beinhalten alle drei Cluster, ebenfalls sortiert nach den Original-Zielgrößen, wobei Cluster 3 wiederum gut erkennbar ist.

Die Grafiken zeigen, dass die KNN-Modellierung für die Kauffälle 0 bis 500 sowie für 7000 bis 8500 eine bessere Adaption an die Original-Größen im Vergleich zur MLR erzielen. Die KNN-Residuen weisen zwar vor allem für Cluster 3 eine größere Streuung auf, im Mittel entspricht die Modellierung jedoch dem tatsächlich beobachteten Wert. Es ist zu vermuten, dass die höhere Varianz der Abweichungen für mittelgroße Kaufpreise (Kauffall 3500–4000) aus der Clusterung (auf Basis der genannten Einflussgrößen) resultiert, da für das Cluster 2 in diesem Segment keine Kauffälle zuzuordnen sind. Weitere Untersuchungen in



INTERGEO® Besuchen Sie uns

17.-19. September 2019 | Stuttgart
RIEGL Stand 11.024, Halle 1

RIEGL LiDAR Waveform-Processing Technologie für UAV/UAS/RPAS

RIEGL bietet eine breite Palette von LiDAR Sensoren für die Integration in unbemannte Luffahrzeuge. Wählen Sie den für Ihre Anwendung optimalen Scanner und profitieren Sie von bewährten RIEGL LiDAR Technologien: ausgereiftes Design, Multiple-Time-Around-Signalverarbeitung, Mehrzielfähigkeit, hochpräzise und aussagekräftige Scandaten, großes Sichtfeld, kundenspezifische Konfigurationen und benutzerfreundliche Integrationsmöglichkeiten.



RIEGL miniVUX-1UAV extrem kleiner, leichter LiDAR Sensor für die Integration in unterschiedlichste UAVs

- max. Einsatzflughöhe 100 m AGL
- bis zu 250 m Messreichweite
- Genauigkeit 15 mm, Präzision 10 mm
- 1,55 kg Gewicht



RIEGL miniVUX-1DL „Downward-Looking“ spezielles Design für Korridor-Mapping-Anwendungen

- max. Einsatzflughöhe 80 m AGL
- bis zu 200 m Messreichweite
- Genauigkeit 15 mm, Präzision 10 mm
- 2,4 kg Gewicht



RIEGL VUX-1UAV vielseitiger und leistungsstarker LiDAR Sensor für die UAV-basierte Vermessung

- max. Einsatzflughöhe 350 m AGL
- bis zu 920 m Messreichweite
- Genauigkeit 10 mm, Präzision 5 mm
- 3,5 kg Gewicht

Informieren Sie sich auch auf www.riegl.com
über weitere RIEGL UAV LiDAR Sensoren!

▶ **RIEGL VUX-240**
für Korridor-Mapping mit hoher Punktdichte

▶ **RIEGL VQ-840-G**
topo-bathymetrischer Scanner für die Küstenvermessung



Bezug auf Auswirkungen der Clusterung und Möglichkeiten der Optimierung sollen in folgenden Arbeiten untersucht werden.

Die Ergebnisse (Tab. 8) bestätigen den bestehenden nichtlinearen Zusammenhang zwischen Wohnflächenpreis und den berücksichtigten Einflussgrößen in diesem heterogenen Datensatz. Die KNN-Modellierung erweist sich als das leistungsfähigere Verfahren, bedarf jedoch für eine sinnvolle Auswertung – abhängig von der Modellkomplexität – großer Datenmengen.

6 FAZIT

Das Ziel dieses Beitrags ist es, zu untersuchen, ob und für welche Arten von Daten die Modellierung mit KNN gegenüber der MLR einen Mehrwert generiert. Insbesondere interessiert die Fragestellung, ob durch eine gemeinsame Auswertung teilmärktübergreifender Daten auch Aussagen über darin integrierte kaufpreisarmer Teilmärkte getätigt werden können. Im Zuge zweier analysierter Stichproben wird eine teilmärktübergreifende Auswertung realisiert. Mit dem Liegenschaftszinssatz aus Niedersachsen werden räumliche Teilmärkte landesübergreifend ausgewertet; der Einfamilienhausmarkt Hannover ermöglicht die Auswertung sachlicher, lokaler Teilmärkte.

Eine Modellierung mit KNN bedarf zuerst der Festlegung einer Modellstruktur, die dem physikalischen Zusammenhang zwischen Einfluss- und Zielgrößen entspricht. Die zu wählende Modellkomplexität ist durch die verfügbaren Trainingsdatenmengen beschränkt. Dies wird empirisch mit einem Beispiel in Abschnitt 5.2 untermauert. Vor allem bei den Einfamilienhäusern zeigt sich, dass die geringe Datenmenge die nichtlineare Modellierung mittels KNN nicht unterstützt und auf Basis der originalen Daten die MLR die bessere Prädiktion liefert. Diese Feststellung ist übereinstimmend mit /Nguyen & Cripps 2001/ und /Zurada et al. 2011/, die ebenfalls zu dem Schluss kommen, dass größere Datenmengen für eine erfolgreiche Modellierung mit nichtlinearen Ansätzen benötigt werden. Jedoch werden dort gewählte Modellstrukturen nicht argumentiert und der Zusammenhang zwischen Modellkomplexität und Datenmengen nicht diskutiert. Weiterführend sei anhand des erfassten Stands der Forschung kritisch angemerkt, dass in zahlreichen Studien meist ebenfalls nur geringe Datenmengen vorliegen und deshalb die gewählte Modellkomplexität der KNN oft nicht zur erwarteten besseren Prädiktionsfähigkeit im Vergleich zur MLR führt. Bei geringer Stichprobenzahl ist die MLR den KNN überlegen, jedoch fehlt es an Angaben hinsichtlich der benötigten minimalen Datenmengen und deren Abhängigkeiten für Immobilienbewertungsdaten.

Um die Zusammenhänge zwischen der Stichprobenanzahl und der Leistungsfähigkeit der Methoden weiter untersuchen zu können, wird die Stichprobe der Einfamilienhäuser in Hannover mittels einer strukturerhaltenden Simulation erweitert. Die damit erwirkte Vervielfältigung der Datenmenge wird auf Basis homogener Untermengen, die im Zuge einer Clusterung entstanden sind, mit einer Support Vector Regression durchgeführt. Die Ergebnisse zeigen, dass mit der KNN-Modellierung eine verbesserte Prädiktionsfähigkeit von 18 % (RMSE) im Vergleich zur MLR erzielt werden kann. Obwohl dies zunächst mit Vorsicht zu betrachten ist, da nur aus

den vorhandenen Werten der Einflussgrößen und teils unabhängig gezogen wird, kann auf Grundlage der Simulation dargestellt werden, dass die KNN für teilmärktübergreifende Analysen unter den geschaffenen Voraussetzungen geeignet sind. Die Auswertung kaufpreisarmer Lagen scheint über die Aggregation mit anderen Teilmärkten zielführend. Hierzu ist in weiteren Analysen ein enger Austausch zwischen Praxis und Forschung notwendig.

Beim Liegenschaftszinssatz-Datensatz ist bei acht Einflussgrößen die Datenmenge adäquat zur Modellkomplexität. Wird die kategoriale Betrachtungsweise verfolgt, wie sie für viele Regressionsanalysen üblich ist, steigt die Dimensionalität des Modells. Für die Modellierung mit KNN bedeutet dies, dass gleichzeitig die Modellkomplexität zunimmt. In diesem Fall ist ebenfalls die Datenmenge die limitierende Größe. Modellierungsvariante 1, bestehend aus den Einflussgrößen Bodenrichtwert, Regionstyp und Kaufjahr, führt zu einer schlechteren Prädiktion als das erweiterte Modell in Variante 2. Durch die nichtlineare Modellierung mit KNN kann eine 5 %ige Verbesserung des RMSE für Variante 2 erzielt werden. Weitere Verbesserungen sind zu erwarten, wenn die Modellierung kategorialer Variablen in KNN zielführender gelöst werden.

7 AUSBLICK

Für die Modellierung des nichtlinearen Zusammenhangs zwischen Einfluss- und Zielgrößen in der Immobilienwertermittlung stellen KNN eine geeignete Methode dar, vorausgesetzt, ein ausreichend großer Stichprobenumfang ist gegeben. Außerdem bieten KNN die Möglichkeit der automatisierten Datenauswertung, was aufgrund von fehlenden Ressourcen wünschenswert ist.

Für die zukünftige Verwendung von KNN in der Wertermittlung bedarf es großer Datensätze. Die Generierung dieser kann durch die Nutzbarmachung von unvollständigen bzw. fehlerhaften Dateneinträgen (Imputation von Daten) oder durch die Entwicklung von Simulationsmethoden erfolgen. Das Ziel ist, eine automatische Ableitung von Kaufpreisen generieren zu können. Dazu soll in weiteren Arbeiten eine vertiefte Auseinandersetzung mit den Möglichkeiten einer Simulation für die strukturerhaltende Erweiterung der Stichproben und mit der Integration von Unsicherheiten in die KNN-Modellierung erfolgen. Darüber hinaus bedarf es der Weiterentwicklung der Methodik hinsichtlich der Handhabung bzw. Modellierbarkeit kategorialer Variablen bzw. Daten auf unterschiedlichen Skalen.

Hierdurch scheint die Auswertung kaufpreisarmer Lagen, aber auch die Modellierung nichtlinearer Zusammenhänge in automatisierten und ressourcenschonenden Verfahren möglich zu werden.

LITERATUR

- Bortz, J.; Schuster, C. (2010): Statistik für Human- und Sozialwissenschaftler. 7. Auflage. Springer, Berlin/Heidelberg/New York.
- Cherkassky, V.; Mulier, F. (1998): Learning from data: concepts, theory, and methods. Wiley-Interscience.
- Din, A.; Hoesli, M.; Bender, A. (2001): Environmental Variables and Real Estate Prices. In: Urban Studies 38(2001)11, 1989–2000.

Fahrmeir, L.; Kneib, T.; Lang, S. (2009): Regression – Modelle, Methoden und Anwendungen. Statistik und ihre Anwendungen. 2. Auflage. Springer, Berlin/Heidelberg/New York.

Fan, C.; Xu, H. (2009): The Review on Non-linear Analysis and Forecasting Methods of the Real Estate Market in China. In: Asian Social Science 4(2009)11, 156–160. <http://www.ccsenet.org/journal/index.php/ass/article/view/830>.

Goldberg, A. (1991): A Course in Econometrics. Harvard University Press, Cambridge.

Gutachterausschuss für Grundstückswerte Hameln-Hannover (2019): Grundstücksmarktberichte Hameln-Hannover. LGLN Regionaldirektion Hameln-Hannover.

Halvorsen, R.; Pollakowski, H. O. (1981): Choice of functional form for hedonic price equations. In: Journal of Urban Economics 10(1981)1, 37–49.

Haykin, S. S. (1999): Neural Networks – A Comprehensive Foundation. 2nd Edition. Prentice Hall, Upper Saddle River.

Heunecke, O.; Kuhlmann, H.; Welsch, W.; Eichhorn, A.; Neuner, H. (2013): Handbuch Ingenieurgeodäsie – Auswertung geodätischer Überwachungs-messungen. 2. Auflage. Wichmann, Berlin/Offenbach.

Hornik, K.; Stinchcombe, M.; White, H. (1989): Multilayer feedforward networks are universal approximators. In: Neural Networks 2(1989)5, 359–366.

James, G.; Witten, D.; Hastie, T.; Tibshirani, R. (2013): An Introduction to Statistical Learning (Vol. 103). Springer, New York.

Koch, K.-R. (1997): Parameterschätzung und Hypothesentests in linearen Modellen. 3. Auflage. Dümmler, Bonn.

Lisi, G. (2013): On the functional form of the hedonic price function: a matching-theoretic model and empirical evidence. In: International Real Estate Review 16(2015)2, 198–207. <https://mpr.ub.uni-muenchen.de/id/eprint/43879>.

Marquardt, D. W. (1963): An Algorithm for Least-Squares Estimation of Non-linear Parameters. In: SIAM Journal on Applied Mathematics 11(1963)2, 431–441.

Mimis, A.; Rovolis, A.; Stamou, M. (2013): Property valuation with artificial neural network: the case of Athens. In: Journal of Property Research 30(2013)2, 128–143.

Nguyen, N.; Cripps, A. (2001): Predicting housing value: A comparison of multiple regression analysis and artificial neural networks. In: Journal of Real Estate Research 22(2001)3, 313–336.

Núñez-Tabales, J.; Caridad, J.; Rey Carmona, F. J. (2013): Artificial neural networks for predicting real estate prices. In: Revista de Metodos Cuantitativos para la Economía y la Empresa, Vol. 15.

Pelzer, H. (1978): Ein indirektes Vergleichswertverfahren unter Anwendung statistischer Methoden. In: Zeitschrift für Vermessungswesen (zfv) 103(1978)6, 245–254.

Soot, M.; Weitkamp, A.; Alkhatib, H.; Dorndorf, A.; Jeschke, A. (2016): Analysis on Different Market Data for Real Estate Valuation – Investigations on German Real Estate Market. FIG Working Week 2016. Christchurch (Neuseeland).

Soot, M.; Weitkamp, A.; Dorndorf, A.; Alkhatib, H.; Jeschke, A. (2017): Different Regions with Few Transactions – An Approach of Systematization. FIG Working Week 2017. Helsinki.

Soot, M.; Zaddach, S.; Weitkamp, A.; Käker, R.; Ziems, M. (2018): Weiterentwicklung der AKS – Implementierung neuer Auswertemethoden und Steigerung der Nutzer-Interaktion. In: Zeitschrift für Geodäsie, Geoinformation und Landmanagement (zfv) 143(2018)1, 24–35.

Stoetzer, M.-W. (2017): Regressionsanalyse in der empirischen Wirtschafts- und Sozialforschung. Band 1: Eine nichtmathematische Einführung mit SPSS und Stata. Springer Gabler, Berlin/Heidelberg.

Tajani, F.; Morano, P.; Locurcio, M.; D’Addabbo, N. (2015): Property Valuations in Times of Crisis. Artificial Neural Networks and Evolutionary Algorithms in Comparison. Lecture Notes in Computer Science, Vol. 9157.

Tay, D.; Ho, D. K. H. (1992): Artificial Intelligence and the Mass Appraisal of Residential Apartments. In: Journal of Property Valuation and Investment 10(1992).

Urban, D.; Mayerl, J. (2011): Regressionsanalyse: Theorie, Technik und Anwendung. VS, Wiesbaden.

Vapnik, V. N. (1999): An overview of statistical learning theory. In: IEEE Transactions on Neural Networks 10(1999)5, 988–999.

Worzala, E.; Lenk, M.; Silva, A. (1995): An Exploration of Neural Networks and Its Application to Real Estate Valuation. In: Journal of Real Estate Research 10(1995)2, 185–201.

Ziegenbein, W. (1977): Zur Anwendung multivariater Verfahren der mathematischen Statistik in der Grundstückswertermittlung. Dissertation, Technische Universität Hannover.

Zurada, J.; Levitan, A.; Guan, J. (2011): A comparison of regression and artificial intelligence methods in a mass appraisal context. In: Journal of Real Estate Research 33(2011)3, 349–387.

Dipl.-Ing. Sabine Horvath

TECHNISCHE UNIVERSITÄT DRESDEN
GEODÄTISCHES INSTITUT

Helmholtzstr. 10 | 01067 Dresden
sabine.horvath@tu-dresden.de



M. Sc. Matthias Soot

TECHNISCHE UNIVERSITÄT DRESDEN
GEODÄTISCHES INSTITUT

Helmholtzstr. 10 | 01067 Dresden
matthias.soot@tu-dresden.de



Prof. Dr.-Ing. Alexandra Weitkamp

TECHNISCHE UNIVERSITÄT DRESDEN
GEODÄTISCHES INSTITUT

Helmholtzstr. 10 | 01067 Dresden
alexandra.weitkamp@tu-dresden.de



Prof. Dr.-Ing. Hans-Berndt Neuner

TECHNISCHE UNIVERSITÄT WIEN
DEPARTMENT FÜR GEODÄSIE
UND GEOINFORMATION

Gußhausstraße 27–29 | 1040 Wien
hans.neuner@geo.tuwien.ac.at



Manuskript eingereicht: 22.07.2019 | Im Peer-Review-Verfahren begutachtet