



David Koch; Matthias Zeppelzauer; Miroslav Despotovic; Maria Döller

ImmoPixel: Immobilien und automatisierte Bilderkennung

118 – Multimedia retrieval, visualisation and data literacy

Abstract

Die Vernetzung von immobilienwirtschaftlichem Know-How mit der Technologie der automatisierten Bilderkennung (image analysis) besteht derzeit aus wissenschaftlicher und wirtschaftlicher Sichtweise noch nicht. Ziel des Forschungsvorhabens „ImmoPixel“ ist der Aufbau und die nachhaltige Positionierung eines Zentrums für Bilderkennung im Kontext der Immobilie. Vor allem die Vereinigung von immobilienwirtschaftlichem Wissen aus dem Themenfeld der Immobilienbewertung und automatisierter Bilderkennung steht dabei im Mittelpunkt. Es werden zwei aktuelle Forschungsprojekte vorgestellt, die einerseits die Gebäudeeigenschaften (S_i) und andererseits die Lage (L_i) mit Hilfe der Bilderkennung klassifiziert. Das Projekt „(I)mmo(A)ge“ klassifiziert das Baujahr bzw. die Bauperiode sowie regionale Bauweisen von Einfamilienhäusern mit Hilfe von Bilderkennungsverfahren. Im zweiten Projekt „ImmBild“ wird eine Lageklassifizierung durch Bildanalyse entwickelt, die ohne weitere externe Daten auskommt – d.h. lediglich durch ein Satellitenbild erfolgt die Klassifizierung. Beide Projekte weisen unterschiedliche Anforderungen hinsichtlich der Daten und methodischen Herangehensweise auf.

Keywords:

Automatische Bilderkennung, Immobilienwirtschaft, Computer Vision, Hedonische Preise, Maschinelles Lernen

Ausgangssituation und Ziel

Aus immobilienökonomischer Sichtweise ist die Wertermittlung einer Immobilie sowohl durch die gesetzlich geregelten Bewertungsverfahren (Vergleich-, Sach- und Ertragswert) gegeben (LBG, 1992), als auch im wissenschaftlichen Diskurs mit der Theorie der hedonischen Preise das theoretische Gerüst für die Immobilienbewertung (Liao & Wang, 2012). Formal, nach der Theorie der hedonischen Preise lässt sich der Wert einer Immobilie wie folgt anschreiben: $P_i = f(S_i, L_i, N_i)$. Wobei P der Preis (Wert) der Immobilie darstellt, S_i einen Vektor mit Gebäudeeigenschaften, L_i einen Vektor mit Lagevariablen und N_i beschreibt Nachbarschaftliche bzw. Umwelteinflüsse wie bspw. da Zinsniveau. (Herath & Maier, 2010), (Sirmans, Macpherson, & Zietz, 2005) und (Sirmans, MacDonald, Macpherson, & Zietz, 2006).

Aufbauend auf dieser Herleitung werden zwei aktuelle Forschungsprojekte vorgestellt, die einerseits die Gebäudeeigenschaften (S_i) und andererseits die Lage (L_i) mit Hilfe der Bilderkennung klassifiziert. Das Projekt „(I)mmo(A)ge“ klassifiziert das Baujahr bzw. die Bauperiode sowie regionale Bauweisen von

Einfamilienhäusern mit Hilfe von Bilderkennungsverfahren. Im zweiten Projekt „*ImmBild*“ wird eine Lageklassifizierung durch Bildanalyse entwickelt, die ohne weitere externe Daten auskommt – d.h. lediglich durch ein Satellitenbild erfolgt die Klassifizierung. Beide Projekte weisen unterschiedliche Anforderungen hinsichtlich der Daten und methodischen Herangehensweise auf.

Durch automatische Bildanalyse wird eine neue Informationsquelle erschlossen werden, die bisher in der Immobilienbewertung bzw. Automated Valuation Model (bspw. hedonischen Modellen) gar nicht berücksichtigt werden konnte. Einerseits wird die Genauigkeit der Modelle durch die Extraktion relevanter Merkmale aus Bildinformationen erhöht und andererseits wird die zukünftige Einsetzbarkeit dieser Modelle in Gebieten möglich, wo abgesehen von Luftaufnahmen keine bzw. nur bedingt „externe“ statistische Daten vorhanden oder verfügbar sind.

Dieser Beitrag stellt gibt einen kurzen Überblick über die beiden Projekte „*(I)mmo(A)ge*“ und „*ImmBild*“ und stellt die Zielsetzung und unsere Herangehensweise vor.

ImmoAge

Idee und Zielsetzung

Hauptziel von *(I)mmo(A)ge* ist die Erkennung des Baujahres von Einfamilienhäusern mit Hilfe von automatischer Bildanalyse. Dabei wird das Baujahr aus einer Frontalansicht des Gebäudes, in der Fassade, Fenster, Dach, Türen, Kamin, etc. ersichtlich sind, abgeleitet werden. Des Weiteren werden regionale bauliche Aspekte analysiert, welche aufgrund der heterogenen, topografischen und klimatischen Bedingungen unterschiedliche Muster hinsichtlich Dimensionierung und Ausprägung von Gebäudeteilen aufweisen. Ein typischer regionaler Aspekt in Österreich ist etwa die Dimensionierung des Dachstuhls und des Vordaches, welche im Westen Österreichs deutlich höher ist als im Osten.

Die Hauptbeiträge zur Forschung beinhalten:

- Erste Methode zur Altersbestimmung von Einfamilienhäusern aus Gebäudeansichten und deren Klassifikation in Bauperioden (z.B. 40er Jahre, 50er Jahre) unter Berücksichtigung regionaler baulicher Eigenschaften.
- Eine Methodik zur Extraktion von visuellen Merkmalen aus Außenaufnahmen, die für bestimmte Bauperioden und Regionen charakteristisch sind.
- Erste Evaluierung zur Übereinstimmung automatisch extrahierter Bauperioden und visueller Merkmale mit manuell vom Experten definierten Epochen und Merkmalen.

Methode und Daten

Als Datenbasis besteht ein einzigartiger umfassender Datensatz mit ca. 100.000 Objekten aus Österreich zur Verfügung. Dieser Datensatz beinhaltet Fotos, Merkmale zur Immobilie und die Wertermittlung von Einfamilienhäusern die von Immobilien Sachverständigen im Rahmen einer Bewertung erstellt worden sind. D.h. es liegen verschiedene gebäudespezifische Kennzahlen wie Baujahr, Zustand, Adresse, Verkehrswert etc. Diese Datenbank dient als Trainingsbasis für die visuelle Merkmalsextraktion. Basierend auf den extrahierten Merkmalen erfolgt dann eine Klassifikation der Bilder.

Zur Erstellung unseres finalen Datensatzes bzw. Ground-Truth verfolgen wir zwei Ansätze die auch entsprechend evaluiert werden. Neben den ursprünglichen Datensatz welcher das konkrete Baujahr sowie das fiktive Baujahr beinhaltet erfolgt eine subjektive Einschätzung der Objekte hinsichtlich ihres

Baujahres, ihrer Bauperiode (Bauklasse) und ihrer Region durch Experten. Die Evaluierung durch Experten besitzt den Vorteil das hier ebenfalls eine Begründung von den Experten vorgenommen wird. Des Weiteren erfolgt eine Einschätzung hinsichtlich des Gebäudetyps, sprich, ob es sich um ein typisches Einfamilienhaus mit typischen Elementen aus der Bauperiode handelt oder eher um ein atypisches Gebäude wie beispielsweise einen Bungalow.

Eine grundlegende Fragestellung im Projekt ist, welche visuellen Merkmale (Elemente) typisch für unterschiedliche Bauperioden und Regionen sind. Verwandte Methoden verwenden üblicherweise Clustering (Goel, Juneja, & Jawahar, 2012) oder überwachtes Lernen (Doersch, Singh, Gupta, Sivic, & Efros, 2012), um repräsentative visuelle Elemente (meistens rechteckige Bildausschnitte, sog. patches) zu finden. Wir verfolgen einen Datamining-orientierten Ansatz, der beliebig geformte visuelle Merkmale finden kann und weniger zu optimierende Parameter aufweist. Ziel ist es möglichst autonom aus gegebenen Bilddaten selbst jene Elemente zu identifizieren, die für unterschiedliche Bauperioden und Regionen am charakteristischsten (diskriminativsten) sind.

Um diese semi-überwachtes Lernproblem (semi-supervised learning) zu evaluieren, wird erfolgt zusätzlich eine „händische“ Bildannotation. Das Ergebnis dieser Annotation ist eine globale Einteilung des Bildes in Vordergrund (Gebäude) und Hintergrund (Umgebung). Anschließend werden lokal einzelne Gebäudeelemente wie Fenster, Türen, Kamine, Balkone, und Dachflächen im Bild segmentiert.

Unsere methodische Baseline bezieht sich auf die Arbeiten von (Lee, Maisonneuve, Crandall, Efros, & Sivic, 2015). Die Autoren analysieren Street-View Bilder, um das grobe Alter der abgebildeten Gebäude zu prognostizieren. Für diesen Zweck kombinieren sie eine Katasterkarte, welche detaillierte Baujahre der Gebäude enthält, mit den Street-View Bildern. Der resultierende Datensatz dient als Trainingsdatensatz für ihre Methode. Die Autoren verwenden Klassifikationsmethoden für die Extraktion von charakteristischen architektonischen Elementen verschiedener Epochen. Ähnlich wie bei (Doersch et al., 2012) extrahieren sie zunächst rechteckige Ausschnitte aus den Bildern. Mit Hilfe der Bildausschnitte und deren visuell ähnlichsten Nachbarn im Trainingsdatensatz werden Klassifikatoren trainiert. Bildausschnitte, deren Klassifikatoren eine hohe Diskriminativität aufweisen (unter Berücksichtigung der Katasterdaten) werden als Kandidaten ausgewählt.

ImmBild

Idee und Zielsetzung

Der Wert einer Immobilie wird wesentlich von der Lage determiniert. Aufgrund der Einzigartigkeit und der unterschiedlichen regionalen Charakteristiken, besteht eine Informationsasymmetrie. Das heißt aktuell wird die Lage von Immobilien von entsprechenden Professionisten wie Sachverständige, Immobilien-treuhänder, etc. eingeschätzt und entsprechend quantifiziert oder aus wissenschaftlicher Sicht mit Hilfe von hedonischen Modellen ermittelt. Im Bereich der hedonischen Modelle, werden jedoch nur jene Aspekte berücksichtigt, die als quantifizierbare Daten auch tatsächlich vorliegen wie bspw. Distanzen zu Schulen, öffentlichen Verkehrsmitteln etc. Ebenso werden auch Daten auf aggregiertem Level wie bspw. soziodemografische Aspekte angewendet, weshalb meist nur auf diesem aggregierten Level eine bestimmte Aussage getroffen werden kann. Daher kann auf den exakten Standort bzw. die unmittelbare Nachbarschaft nur bedingt eine vollständig automatisierte Bewertung stattfinden. Dabei ist die Betrachtung der Lage auf kleinräumiger Struktur zentral, da bspw. ein wesentlicher Unterschied besteht, direkt an der Hauptstraße zu wohnen oder in der zweiten Reihe.

Einerseits besteht die Datenlage auf einem zu aggregierten Level für hedonische Modelle und andererseits sind gewisse Aspekte nicht in einer Datenform vorhanden bspw. der Blick.

Nachfolgende Abbildung 1 soll den Aspekt der bildbasierten Idee darstellen, während der linke Ausschnitt eine weniger beliebte Wohngegend zeigt, wird im rechten Ausschnitt eine beliebte Wohngegend dargestellt.



Abb. 1: Beispielhafte Ausschnitt aus der Stadt Kufstein (Links Endach: weniger beliebte Wohnlage; Rechts: beliebte Wohngegend).

Das Ziel des Projekts „ImmBild“ ist die automatische Extraktion von Lagebewertungskennzahlen aus Satellitenbildern für die Modellierung und Erstellung von Lagebewertungen. Als Input kommen dabei RGB Satellitenbilder zur Anwendung, welche für die meisten Regionen in hoher Qualität verfügbar sind. Anschließend werden Bildanalysemethoden und –modelle auf dem entwickelt, die Objekte und Landnutzungen automatisiert extrahieren, quantifizieren und daraus Lagekennzahlen ableiten. Diese bildbasierten Lagekennzahlen werden dann in Lagemodelle integriert und evaluiert. Der gesamte Prozess läuft dabei ohne Benutzereingaben ab.

Methode und Daten

Methodisch gliedert sich die Vorgangsweise in folgende Abschnitte:

1. Anforderungsanalyse
2. Lagestudie
3. Datenaufbereitung, Annotation und Datensatzgenerierung
4. Modellierung visueller Merkmale und Training von Bildklassifikatoren
5. Bildbasierte Kennzahlextraktion
6. Lagemodellierung & Evaluation

Anforderungsanalyse

Generell besteht bereits ein Überblick über die theoretischen Konzepte sowie ein vertiefendes Verständnis aus immobilienökonomischer Sichtweise. Dieser wird durch die Fachrichtung Regionalökonomie und Geografie entsprechend im Detail vertieft und kombiniert. Die Erkenntnisse aus dieser theoretischen thematischen Aufbereitung werden in einem hierarchischen Lagemodell entsprechend vereint. Das Modell soll in Anlehnung an die Österreichische Bewertungslehre (Bienert & Funk, 2014; Kleiber, 2013; Kranewitter, 2012) sowie auch in Anlehnung an das Marktrating der TEGoVA (TEGoVA, 2003) entsprechend aufbereitet werden (Makro-, Mikro und Standortlage).

Lagestudie

Die Lageevaluierung erfolgt mit drei unterschiedlichen Ansätzen. (i) Experteninterviews (ii) Befragungen (Experiment) von Laien und (iii) Lageermittlung durch Regressionsanalysen von Preisen bzw. Mieten.

- Lagebefragung Experten: Da Immobilienmärkte als fragmentiert anzusehen sind, ist jeder Markt regional anders zu klassifizieren und daher muss eine individuelle Betrachtung der Märkte durchgeführt werden. Deshalb werden ausgewählte Regionen regionalen Experten (z.B. Sachverständige) gezeigt und diese klassifizieren im Anschluss die entsprechenden Lageregionen und geben Durchschnittspreise für kleinräumige Bereiche an. Das Interview wird mit Hilfe eines strukturierten Leitfadens durchgeführt.
- Lagestudie mit Laien: Es werden Experimente bzw. Befragungen bei Laien durchgeführt, welche Aspekte ihnen hinsichtlich der Lage wichtig sind. Ebenso werden ihnen unterschiedliche Regionen gezeigt und es muss eine Einteilung der Lage durch die Befragten vorgenommen werden. Hier steht einerseits die Quantifizierung im Vordergrund, aber vor allem auch die Unterscheidung der Lageparameter hinsichtlich des Geschlechtes. Dabei wird die Befragung mit einem offenen Fragebogen gestellt, um einerseits die spontane Antwort in eigenen Worten abzubilden, da andererseits vorgegebene Angaben zu einer Verzerrung der Antworten führen, da die Probandinnen und Probanden an die vorgegebenen Aspekte unter Umständen gar nicht gedacht hätten (O’Cathain & Thomas, 2004; Schuman & Presser, 1979). Jedoch wird ein geschlossener Fragebogen durchgeführt, um ebenso ein Ranking der vorgegebenen Parameter aus der Literatur zu analysieren.
- Regressionsanalyse mit Preisen: Auf Basis von Transaktions- Angebots- sowie Verkehrswertermittlungen von Immobiliensachverständigen werden Regressionsanalysen zur Quantifizierung von wertbeeinflussenden Umständen (Entfernungen, Soziodemografische Aspekte etc.) angewendet. In diesem Zusammenhang werden entsprechende Datensätze verwendet, die sowohl die Immobilienpreis Eigenschaften, als auch die regionalen Eigenschaften auf Zählspen-gelebene widerspiegeln.

Datenaufbereitung, Annotation und Datensatzgenerierung

Zur Datensatzgenerierung kommen primär frei verfügbare GIS Daten zum Einsatz – wie etwa Open Government Data (Tiris, 2016) – welche hochauflösende Satellitenbilder und hochqualitative Metadaten (Gebäude, Parzellengrenzen, Landnutzungen etc.) zur Verfügung stellen, siehe Abb. .

In der Anforderungsanalyse zu Beginn des Projekts werden die Metadaten (GIS Daten), welche für die Ableitung von bildbasierten Bewertungskennzahlen notwendig sind, erhoben. In einer anschließenden Annotationsphase, werden jene Daten, welche noch nicht aus vorhandenen GIS Daten gewonnen werden können, durch Annotation manuell erstellt. Ebenfalls wird die Ground-Truth zur Lagequalität als separater Layer manuell erstellt. Die Einteilung der Lageklassifikation erfolgt einerseits nach der 10-teiligen Skala nach TEGoVA (TEGoVA, 2003) und ebenso nach dem etablierten Immobilienpreisspiegel der Wirtschaftskammer (Wirtschaftskammer Österreich (Hrsg.), 2016). Die Immobilienpreise liegen für Transaktionspreise sowie die Wertermittlungen von Sachverständigen als Punktkoordinate vor. Angebotspreise (von Online Plattformen) liegen jedoch zu ca. 90% auf Gemeindeebene vor. Ebenso liegen die Immobilienpreise der Wirtschaftskammer (Wirtschaftskammer Österreich (Hrsg.), 2016) vor, welche seit 2000 für 12 Immobilienkategorien die Preise auf vier verschiedenen Lagekriterien auf Bezirksebene für Österreich erhoben hat. Aufgrund dieser Datenstruktur wird ein hierarchisches Model (W. a. Brunauer, Lang, & Feilmayr, 2013), (W. A. Brunauer, Lang, & Umlauf, 2013) zur Preisermittlung angewendet.

Aus den erstellten Annotationen, den Satellitenbildern und den dazugehörigen GIS Daten wird ein erster Datensatz für automatische bildbasierte Lagebewertung erstellt.



Abb. 2: Orthofoto (links), überlagerte GIS Daten für die Kategorien: Gebäude, Wasser, Straßen (regional und überregional), Parkplatz, Bahn, Wald, Landwirtschaftliche Nutzflächen.

Modellierung visueller Merkmale und Training von Bildklassifikatoren

Die Extraktion repräsentativer visueller Merkmale stellt die Kernaufgabe in der Bildanalyse dar. Wir wenden Ende-zu-Ende Lernverfahren (Deep Learning) an, um zielgerichtet aussagekräftige und diskriminative Merkmale automatisch aus den Bilddaten zu lernen. Anschließend werden die Merkmale für bestimmte Analyseaufgaben verfeinert und angepasst und direkt in den Klassifikationsprozess integriert.

Als Basis verwenden wir vortrainierte Netze, welche wir in der Vergangenheit bereits erfolgreich für unterschiedliche Bildanalyseaufgaben adaptiert haben (Salvador, Zeppelzauer, Manchon-Vizuete, Calafell, & Giro-i-Nieto, 2015). Da Netze, welche auf Fotos (z.B. aus der ImageNet Datenbank (Socher, 2009)) vortrainiert wurden Strukturen in Satellitenbildern nicht hinreichend repräsentieren, wie in (Basu et al., 2015a) gezeigt wurde, wenden wir ein unüberwachtes iteratives Training auf den bereits vortrainierten Netzen an, um allgemeinere und für Satellitenbilder repräsentative Merkmale (Filter) auf allen Ebenen der Netze zu lernen (Aljundi & Tuytelaars, 2016), (Ganin & Lempitsky, 2014). Als Datenquellen kommen dabei Satellitenbilder aus Datensätzen wie dem US-Merced Datensatz (Yang & Newsam, 2010) und von TIRIS (Tiris, 2016) zur Anwendung. Dieses „re-training“ erzeugt eine allgemeine *Domänenanpassung* des Netzes an Luftbilder aber vorerst noch keine Spezialisierung für eine bestimmte Analyseaufgabe. Durch statistische Analyse der intrinsischen Dimension der so erhaltenen Merkmale wird der Effekt der Anpassung evaluiert und quantifiziert (Basu et al., 2015a).

Nach dieser unüberwachten Adaptionphase (Domain Adaption) werden die neuronalen Netze für unterschiedliche Aufgaben, z.B. Detektion von Gebäuden, Straßen und anderen Landnutzungstypen durch überwachtes Training ausdifferenziert/optimiert. Für das Training werden die automatisch und manuell erstellten Annotationen aus dem aufgebauten Datensatz (s.o.) herangezogen. In dieser Phase erfolgt die Adaptierung primär auf den tieferen (abstrakteren) Schichten des Netzes, um abstrakte diskriminative Merkmale für die gesuchten Entitäten zu lernen.

Besonderes Augenmerk wird auf die Generalisierungsfähigkeit der trainierten Netze gelegt, d.h. inwieweit Netze, welche auf einer bestimmten Region im Satellitenbild trainiert wurden auch robust auf andere zuvor nicht gesehene Regionen anwendbar sind. Zur Erhöhung der Robustheit der Netze sollen Architekturen genutzt werden (siamesische Netze (Chopra, Hadsell, & LeCun, n.d.)), welche sowohl das Bild direkt (in Form von Patches) als auch vorberechnete Merkmale (Basu et al., 2015a) parallel dazu als Input verarbeiten und aus diesen Daten abstraktere (high-level) Merkmale ableiten. Diese Kombination von traditionellen mit autonom gelernten Merkmalen ist ein neuer Ansatz im Bereich der

Satellitenbildanalyse und verbindet die Stärken von state-of-the-art Methoden ((Basu et al., 2015b), (Castelluccio, Poggi, Sansone, & Verdoliva, 2015)).

Bildbasierte Kennzahlextraktion

Basierend auf den vortrainierten Netzen für Objekte und Landnutzungstypen kann das Satellitenbild grob in unterschiedliche Landnutzungen unterteilt werden. Basierend auf dieser Information werden in Abstimmung mit den Experten aus der Immobilienwirtschaft geeignete Lagekennzahlen der Mikro- und Makrolage ausgewählt, die aus der lokalen Landnutzung abgeleitet werden können. Beispiele umfassen etwa die Verkehrssituation (z.B. Nähe von Landstraßen, Autobahnen, Dichte des Verkehrsnetzes), die Nähe von Wasserflächen und Grünflächen, der Anteil solcher Flächen in der direkten Nachbarschaft und in der ferneren Umgebung sowie die Art der Umgebungsbebauung (Einfamilienhäuser, größere Wohnhausanlagen).

Für ausgewählte Lagekennzahlen (z.B. Gebäudedichte) soll evaluiert werden, ob eine direkte Extraktion aus den Bilddaten möglich ist ohne vorher Objektdetektoren anzuwenden (unter Berücksichtigung einer größeren Nachbarschaft als für die Objekterkennung). Schließlich sollen untersucht werden inwiefern abstraktere Kennzahlen, wie z.B. die Akademikerquote, welche einen besonders hohen Einfluss auf die Lagequalität hat, aus den Daten approximiert werden kann. Ähnlich wie in (Xie, Jean, Burke, Lobell, & Ermon, 2015) sollen in einem transferbasierten Lernansatz soziodemographische Indikatoren und GIS Daten z.B. Daten auf Sprengel Ebene oder Rasterdaten genutzt werden, um autonom visuelle Merkmale, die mit der Akademikerquote korrelieren zu lernen. Ein Beispiel für ein charakteristisches visuelles Merkmal könnte etwa eine Häufung von Swimmingpools und Teichen in Wohngebieten sein sowie die Dichte und Größe der Häuser. Die Qualität und Eignung der Kennzahlen wird anschließend durch Integration in Lagemodelle evaluiert (s.u.) bzw. durch Abgleich (Korrelationsanalyse) mit vorhandenen GIS Daten und den zu Beginn des Projekts erstellten Annotationen zur Lagequalität.

Lagemodellierung & Evaluation

Die Lagemodellierung erfolgt mit Hilfe von Regressionsanalysen. Grundsätzlich wird einerseits der Preis bzw. Miete als abhängige Variable modelliert (metrische Variable) und andererseits die Einschätzungen der Experten bzw. Laien die als kategoriale Variablen vorliegen.

Zusammenfassung und Ausblick

Nachfolgend wurden zwei Projekte beschrieben die im Rahmen von "ImmoPixel" aktuell durchgeführt werden. Mit Hilfe dieser Projekte wird generell die automatische Bilderkennung im Bereich der Immobilienwirtschaft erschlossen. Wir sehen in der Kombination aus automatischer Bilderkennung und immobilienwirtschaftlichen Kontext ein hohes wissenschaftliches als auch wirtschaftliches Potential.

Literaturverzeichnis

Aljundi, R., & Tuytelaars, T. (2016). Lightweight Unsupervised Domain Adaptation by Convolutional Filter Reconstruction. *Computer Vision and Pattern Recognition*.

Basu, S., Ganguly, S., Mukhopadhyay, S., DiBiano, R., Karki, M., & Nemani, R. (2015a). DeepSat - A Learning framework for Satellite Imagery. *arXiv.org Preprint*. *Computer Vision and Pattern Recognition*.

- Basu, S., Ganguly, S., Mukhopadhyay, S., DiBiano, R., Karki, M., & Nemani, R. (2015b). DeepSat - A Learning framework for Satellite Imagery. *arXiv.org Preprint*. Computer Vision and Pattern Recognition. Retrieved from <http://arxiv.org/abs/1509.03602>
- Bienert, S., & Funk, M. (Eds.). (2014). *Immobilienbewertung Österreich* (3. Aufl.). Wien: ÖVI Immobilienakademie.
- Brunauer, W. a., Lang, S., & Feilmayr, W. (2013). Hybrid multilevel STAR models for hedonic house prices. *Jahrbuch Für Regionalwissenschaft*, 151–172. <http://doi.org/10.1007/s10037-013-0074-9>
- Brunauer, W. A., Lang, S., & Umlauf, N. (2013). Modelling house prices using multilevel structured additive regression. *Statistical Modelling*, 13(2), 95–123. <http://doi.org/10.1177/1471082X13475385>
- Castelluccio, M., Poggi, G., Sansone, C., & Verdoliva, L. (2015). Land Use Classification in Remote Sensing Images by Convolutional Neural Networks. *Arxiv Preprint arXiv:1508.00092*. Computer Vision and Pattern Recognition.
- Chopra, S., Hadsell, R., & LeCun, Y. (n.d.). Learning a Similarity Metric Discriminatively, with Application to Face Verification. In *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)* (Vol. 1, pp. 539–546). IEEE. <http://doi.org/10.1109/CVPR.2005.202>
- Doersch, C., Singh, S., Gupta, A., Sivic, J., & Efros, A. (2012). What Makes Paris Look like Paris ? To cite this version : *ACM Transactions on Graphics*, 31(4).
- Ganin, Y., & Lempitsky, V. (2014). Unsupervised Domain Adaptation by Backpropagation. *Machine Learning; Learning; Neural and Evolutionary Computing*.
- Goel, A., Juneja, M., & Jawahar, C. V. (2012). Are Buildings Only Instances ? Exploration in Architectural Style Categories. In *Proceedings of the Eighth Indian Conference on Computer Vision, Graphics and Image Processing*. ACM. <http://doi.org/10.1145/2425333.2425334>
- Herath, S., & Maier, G. (2010). The hedonic price method in real estate and housing market research: a review of the literature. In *SRE-Discussion Papers* (pp. 1–16). Vienna: WU Vienna University of Economics and Business.
- Kleiber, W. (2013). *Verkehrswertermittlung von Grundstücken: (7th ed.)*. Bundesanzeiger Verlag.
- Kranewitter, H. (2012). *Liegenschaftsbewertung* (6., [v{ö}]). Wien: Manz.
- LBG. Bundesgesetz über die gerichtliche Bewertung von Liegenschaften (Liegenschaftsbewertungsgesetz - LBG) (1992). Österreich: Bundesrecht.
- Lee, S., Maisonneuve, N., Crandall, D., Efros, A. A., & Sivic, J. (2015, April 24). Linking Past to Present: Discovering Style in Two Centuries of Architecture. *IEEE International Conference on Computational Photography*. Retrieved from <https://hal.inria.fr/hal-01152482/>
- Liao, W.-C., & Wang, X. (2012). Hedonic house prices and spatial quantile regression. *Journal of Housing Economics*, 21(1), 16–27. <http://doi.org/http://dx.doi.org/10.1016/j.jhe.2011.11.001>

- O’Cathain, A., & Thomas, K. J. (2004). “Any other comments?” Open questions on questionnaires - a bane or a bonus to research? *BMC Medical Research Methodology*, 4(1), 25. <http://doi.org/10.1186/1471-2288-4-25>
- Salvador, A., Zeppelzauer, M., Manchon-Vizuete, D., Calafell, A., & Giro-i-Nieto, X. (2015). Cultural Event Recognition With Visual ConvNets and Temporal Models. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops* (pp. 36–44).
- Schuman, H., & Presser, S. (1979). The Open and Closed Question. *American Sociological Review*, 44(5), 692–712. <http://doi.org/10.2307/2094521>
- Sirmans, G. S., MacDonald, L., Macpherson, D. a., & Zietz, E. N. (2006). The Value of Housing Characteristics: A Meta Analysis. *The Journal of Real Estate Finance and Economics*, 33(3), 215–240. <http://doi.org/10.1007/s11146-006-9983-5>
- Sirmans, G. S., Macpherson, D. A., & Zietz, E. N. (2005). The Composition of Hedonic Pricing Models. *Journal of Real Estate Literature*, 13(1), 3–43. Retrieved from <http://cbeweb-1.fullerton.edu/finance/jrel/>
- Socher, R. (2009). ImageNet: A large-scale hierarchical image database. In *2009 IEEE Conference on Computer Vision and Pattern Recognition* (pp. 248–255). IEEE. <http://doi.org/10.1109/CVPR.2009.5206848>
- TEGoVA. (2003). *Europäisches Objekt- und Markttrating: Ein Leitfadens für Gutachter*. London, UK.
- Tiris. (2016). *tiris - Tiroler Rauminformationssystem*, Landesregierung Tirol.
- Wirtschaftskammer Österreich (Hrsg.). (2016). *Immobilienpreisspiegel*. Wien.
- Xie, M., Jean, N., Burke, M., Lobell, D., & Ermon, S. (2015). Transfer Learning from Deep Features for Remote Sensing and Poverty Mapping. *arXiv.org Preprint*, 16. Computer Vision and Pattern Recognition; Computers and Society.
- Yang, Y., & Newsam, S. (2010). Bag-of-visual-words and spatial extensions for land-use classification. In *Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems - GIS '10* (p. 270). New York, New York, USA: ACM Press. <http://doi.org/10.1145/1869790.1869829>