

Masterthesis

De voorspellende kracht van online zoekgedrag op de Nederlandse woningmarkt

Tom Verhoeven

*MSc Real Estate Studies
Rijksuniversiteit Groningen*

8 augustus 2018

Abstract

Gedreven door toegenomen datatransparantie en databeschikbaarheid worden er tegenwoordig diverse nieuwe methoden en alternatieve databronnen onderzocht om de traditionele voorspellende modellen te verbeteren. Data omtrent de zoekintensiteit naar zoektermen, verkregen middels Google Trends, is binnen een breed scala aan vak- en onderzoeksgebieden van toegevoegde waarde gebleken. In dit onderzoek, gebaseerd op ARIMA- en ARIMAX econometrische modellen, is de toegevoegde waarde van Google Trends data verkend in de voorspelling van Nederlandse huizenprijzen. Op deze manier combineert dit onderzoek technische- (historische data woningprijzontwikkeling) en fundamentele analyse (Sentiment indicatoren). De resultaten tonen aan dat de actuele zoekintensiteit naar het woord “Funda” een waardevolle proxy is voor het marktsentiment in de voorspelling van de prijsontwikkelingen op de woningmarkt 5 en 6 maanden later. Uit een vergelijking met de ‘klassieke’ sentiment indicator consumentenvertrouwen blijkt dat de “Funda” parameter er niet in slaagt de woningprijzen accurater te benaderen. Een combinatie van beide variabelen leidt echter wel tot een betere voorspellende kracht en dus een nauwkeuriger en effectiever model dan de afzonderlijke modellen. Dit onderzoek onderschrijft dat Google Trends dus niet enkel in staat is de woningprijzen te voorspellen maar ook van unieke toegevoegde waarde is ten opzichte van de gangbare sentimentindicator, het consumentenvertrouwen. Daarnaast wordt, met het resultaat dat de woningprijzen voorspeld kunnen worden op basis van voorgenoemde variabelen, bijgedragen aan de bredere discussie binnen de wetenschappelijke literatuur omtrent de (in)efficiëntie van de woningmarkt.

Keywords: Google Trends, ARIMAX, huizenprijzen, voorspellen, consumentenvertrouwen, sentiment

Colofon

Datum	8-8-2018
Auteur	T.A.M.J. (Tom) Verhoeven
E-mail	tamj.ver@gmail.com (privé) t.a.m.j.verhoeven@student.rug.nl (studie)
Document	Masterthesis
Studentnr.	S3038572
Universiteit	Rijksuniversiteit Groningen
Faculteit	Faculteit Ruimtelijke Wetenschappen
Studie	MSc Real Estate Studies
1 ^o Begeleider	dr. F.J. Sijtsma
2 ^o Begeleider	dr. M.N. Daams



**rijksuniversiteit
groningen**

Inhoudsopgave

1. Introductie	4
2. Literatuur.....	7
2.1 Woningmarkt voorspellingen en sentiment	7
2.2 Google Trends; Niet-vastgoed gerelateerd.....	10
2.3 Google Trends; Vastgoed-gerelateerd.....	12
2.4 Google Trends; zoektermen	13
2.5 Hypotheses	16
3. Data en methodologie	17
3.1 Data.....	17
3.2 ARIMA/ARIMAX.....	19
4. Resultaten.....	22
4.1 Totstandkoming basismodel	22
4.2 Toevoeging verklarende variabelen	27
5. Conclusie en discussie	33
Bibliografie	36
Bijlagen.....	40
Bijlage A: Analyse diverse onderzoeken	40
Bijlage B: Uitkomsten AIC en BIC	41
Bijlage C: Controle Residuen	42

1. Introductie

In 2009 publiceerden Ginsberg et al. een baanbrekend onderzoek. In hun onderzoek “*Detecting influenza epidemics using search engine query data*” hebben zij een directe relatie gevonden tussen een stijging in de online zoekfrequentie naar griep gerelateerde zoektermen in Google en een latere stijging in het aantal griepgevallen en epidemieën. Hun methode stelde hen in staat griepuitbraken eerder en nauwkeuriger te voorspellen dan de gevestigde instanties op dat gebied. Dit onderzoek lag aan de wieg van een breed scala aan onderzoeken en onderzoeksvelden waarin gebruik gemaakt wordt van Google data. Binnen de vastgoedsector wordt veel gebruik gemaakt van voorspellende modellen. Het is evident dat voorspellingen van woningtransacties en huizenprijzen relevant zijn voor een groot aantal stakeholders zoals ontwikkelaars, beleggers, bestuurders, planologen, politici en economen. In deze studie is onderzocht wat de toegevoegde waarde is van Google data bij de voorspelling van de woningprijzen binnen Nederland. De hoofdvraag van dit onderzoek luidt: *In hoeverre kan data over online zoekgedrag de kwaliteit van korte termijn voorspellingen van de woningmarkt verbeteren?*

Al geruime tijd wordt er onderzoek gedaan naar modellen die dynamieken binnen de woningmarkt kunnen voorspellen. Binnen de literatuur bestaat er geen consensus welke rol sentiment speelt binnen voorspellende modellen toegepast op de woningmarkt (Maier & Herath, 2009). Fama (1970) gaat uit van een efficiënte markt waarbij prijsontwikkelingen een random walk vertonen en het gedrag van consumenten berust op ratio. Sentiment bekeken vanuit dit perspectief is dus een reflectie van onderliggende fundamentele parameters. Shiller (2008) beweert echter op basis van resultaten uit zijn onderzoek dat schommelingen in de woningmarkt veelal gepaard gaan met substantiële psychologische elementen (sentiment), waardoor deze niet alleen verklaard kunnen worden door de klassieke fundamentele economische factoren. Overeenkomstig met Shiller onderstrepen ook Dietzel et al. (2014) het belang van het incorporeren van het onderliggende ‘sentiment’ in voorspellende modellen. Dietzel et al. erkennen het probleem van het kwantificeren van dit sentiment maar benadrukken net als Shiller dat het niet correct is voorspellingen enkel op fundamentele (economische) factoren te baseren. In lijn met de visies van Shiller en Dietzel et al., en tegenstrijdig met de visie van Fama, suggereert Glaeser (2008) dat het sentiment in de markt niet enkel op ratio berust maar ook irrationele overdrijvingen reflecteert. Ondanks de verschillende visies en invalshoeken wordt in beide gevallen gestreefd (direct- dan wel indirect) het sentiment in modellen te vangen.

Er zijn dan ook diverse onderzoeken verricht waarin getracht is het sentiment tot uiting te laten komen in (woning)markt voorspellende modellen. In deze onderzoeken worden veelal de

voorspellende kracht van enquêtes en diverse consumentvertrouwen- en woningmarktindices geanalyseerd (Weber & Devaney, 1996; Marcato & Nanda, 2014). Deze onderzoeken tonen aan dat klassieke fundamentele (macro-economische) indicatoren meermaals “verslagen” worden. Dan wel dat deze aangevuld dienen te worden door indicatoren die het actuele sentiment in de markt weten weer te geven om te komen tot betere voorspellingen van de woningmarkt.

Sinds 2006 heeft Google data met betrekking tot zoektermen publiekelijk toegankelijk gemaakt door middel van de applicatie Google Trends. Het vrijgeven van dergelijke data heeft naast het voorspellen van griepepidemieën geleid tot diverse studies binnen een hoge variëteit aan, met name sociaal- en economisch georiënteerde, onderzoeksrichtingen (Vosen & Schmidt, 2011; Önder, 2017; Askitas & Zimmermann, 2009; Choi & Varian, 2012). De data wordt bijvoorbeeld ook gebruikt door centrale banken¹ bij de voorspelling van economische ontwikkelingen. Daarnaast is de relatie gelegd en gekwantificeerd tussen online zoektermen en bijvoorbeeld de koers van de Bitcoin (Das, 2013; Kristoufek, 2013). Askitas en Zimmermann (2009) vinden bewijs dat Google Insights (nu Google Trends) bruikbaar kan zijn om werkloosheidcijfers te voorspellen in Duitsland en ook binnen de toerisme-industrie is het gebruik van Google data populair.

Onderzoek naar de voorspellende kracht van online zoekgedrag, in het bijzonder Google Trends, is ten opzichte van bestaande theoretisch voorspellende modellen een relatief nieuw en groeiend onderzoeksveld (Jun, Yoo, & Choi, 2017). De mogelijkheid om real-time data te verzamelen en analyseren met Google Trends maakt het mogelijk om het actuele ‘sentiment’ in de markt te analyseren. Dergelijke informatie biedt dan ook kansen om de kwaliteit van de voorspellingen binnen de woningmarkt te verbeteren (Wu & Brynjolfsson, 2015).

Tot op heden hebben er diverse onderzoeken plaatsgevonden naar de voorspellende kracht van online zoekgedrag, en specifiek de toegevoegde waarde van Google Trends. Echter een analyse ontbreekt van de toegevoegde waarde van Google Trends als indicator van het sentiment in de voorspelling van de woningmarkt in Nederland. In dit onderzoek wordt onderzocht of de gegevens van Google Trends van toegevoegde waarde zijn bij de voorspelling van de feitelijke ontwikkelingen op een later moment en welke zoektermen hierbij het meest van belang zijn. Ook wordt de relatie tussen deze gegevens en het consumentenvertrouwen geanalyseerd, een ‘klassieke’ fundamentele parameter. Dit

¹ Kumar Das (2013) ziet Google Trends gebruikt worden door de centrale banken van onder andere: Israël, Groot Brittannië, Italië, Spanje, Turkije en Chili.

onderzoek combineert fundamentele- (door het incorporeren van fundamentele onderliggende parameters) en technische analyse (op basis van data omtrent historische woningprijsontwikkelingen) en is uniek door het gebruik van ARIMA- en ARIMAX-modellen bij het verkennen van de relatie tussen Google data en de Nederlandse woningmarkt.

Dit onderzoek is als volgt ingericht: in het volgende hoofdstuk, hoofdstuk 2, wordt een literatuurstudie gedaan naar thema's gerelateerd aan voorspellende modellen, sentiment en de toepasbaarheid van Google Trends data. Gevolgd door hoofdstuk 3 waarin de methodologie en databronnen worden toegelicht. In hoofdstuk 4 worden de onderzoeksresultaten weergegeven en tot slot in hoofdstuk 5 de conclusie, discussie en beperkingen van dit onderzoek.

2. Literatuur

De analyse van de relevante wetenschappelijke literatuur bestaat uit het bestuderen van drie thema's: (1) de literatuur betreffende het gebruik van voorspellende modellen binnen de woningmarkt in relatie tot het incorporeren van de effecten van het (zoek)gedrag/sentiment van kopers en verkopers, (2) de onderzoeken waarin voorspellende modellen op basis van Google Trends data zijn toegepast op niet-vastgoed gerelateerde vakgebieden en (3) de onderzoeken naar voorspellende modellen die gebruik maken van Google Trends data en betrekking hebben op de vastgoedsector en woningmarkt.

2.1 Woningmarkt voorspellingen en sentiment

Er zijn twee hoofdmethoden voor het voorspellen van vastgoedmarkt trends en ontwikkelingen, te weten *technische-* en *fundamentele analyse* (Wu & Brynjolfsson, 2015). *Technische analyse* wordt met name toegepast bij voorspellingen van beurskoersen. Toegepast op de woningmarkt berust deze methode op het uitgangspunt en de aanname dat de belangrijkste statistische regelmatigheden van veranderingen in de woningmarkt niet veranderen. Hierdoor kunnen historische trendlijnen geanalyseerd worden om een voorspelling te kunnen doen over het toekomstige verloop daarvan. *Fundamentele analyse* is gebaseerd op de onderliggende fundamentele economische indicatoren. Indicatoren die verklarend zijn voor de ontwikkelingen binnen de woningmarkt zijn bijvoorbeeld het besteedbaar inkomen, de interestvoet en diverse demografische variabelen (Égert & Mihaljek, 2007). Veel van de analytische modellen bevatten met name variabelen als: het inkomen, de inflatie en de hypotheekrente (De Vries, 2010). Ondanks dat deze data met een hoge frequentie gepubliceerd wordt is het nadeel daarvan dat het geen real-time informatie betreft en de variabelen veelal geen direct verband met de woningmarkt hebben en dus hooguit op indirecte wijze een sentiment-indicatie kunnen bieden (Dietzel, 2016).

Een relevante theorie die een interessante invalshoek biedt ten aanzien van de relatie tussen voorspellende modellen en de vastgoedmarkt is het gedachtegoed van de 'Efficiënte Markt Hypothese' (EMH). Deze theorie is gebaseerd op de aanname dat financiële markten volledig efficiënt zijn ten gevolge van de transparantie van informatie. Dit maakt het onmogelijk om beter te presteren dan de markt waardoor een disequilibrium tussen vraag en aanbod onmogelijk is. De marktprijzen reflecteren alle fundamentele onderleggers en informatie of nieuws. In een optimale situatie is er volgens de EMH, een evenwicht tussen vraag en aanbod op de vastgoedmarkt (Fama, 1970; Maier & Herath, 2009). De EMH impliceert dan ook dat historische datareeksen geen voorspellende kracht bevatten en dat prijsontwikkelingen een

random walk/random patroon vertonen (Fama, 1970) en is tegenstrijdig met zowel het gedachtegoed van de technische analyse als dat van de fundamentele analyse.

Wanneer we de uitgangspunten van de EMH van toepassing verklaren op de vastgoedmarkt impliceert dit dat er ook op de vastgoedmarkt een equilibrium tussen vraag en aanbod bestaat. In werkelijkheid wordt de efficiënte werking van de prijsvorming bemoeilijkt door diverse karakteristieken van de woningmarkt die duiden op imperfectie en inefficiëntie. Voorbeelden hiervan zijn het ontbreken van volledige datatransparantie, de invloed van transactiekosten, de prijsvolatiliteit en cyclische factoren (Wu & Brynjolfsson, 2015). Woningen worden weinig en onregelmatig verkocht, er vindt relatief veel regulering plaats, transacties komen na besloten onderhandelingen tot stand en het in-elastische aanbod reageert vertraagd op de vraag. Als resultaat hiervan bevinden vraag en aanbod zich zelden tot nooit in een equilibrium-situatie en kent de woningmarkt dan ook een cyclisch karakter (Dietzel, Braun, & Schäfers, 2014). Dit toont aan dat de werking van de vastgoedmarkt imperfect en niet efficiënt is waardoor de marktprijs niet volgens een automatisme op optimale wijze tot stand komt en het dus wel degelijk mogelijk is om op basis van (data)analyse voorspellingen ten aanzien van de werking van de vastgoedmarkt in het algemeen en de woningmarkt in het bijzonder te doen.

Maier en Herath (2009) hebben op basis van een literatuurstudie onderzoek gedaan naar de vraag of de vastgoedmarkt wel of niet efficiënt is. Uit dit onderzoek blijkt dat de wetenschappelijke literatuur hier geen eenduidig antwoord op biedt (Maier & Herath, 2009). Toch is er ook bewijs dat de woningmarkt voorspeld kan worden. Enerzijds is bewezen dat er sprake is van een sterke autocorrelatie in de woningprijzen wat het zinvol maakt om technische analyses uit te voeren (Wu & Brynjolfsson, 2015; Case & Shiller, 1989; Tse, 1997). Daarnaast is ook de toegevoegde waarde van fundamentele analyse meermaals bevestigd door middel van analyses van de relatie tussen macro-economische parameters en de woningmarkt (Figurska & Wisniewski, 2016).

Naast de technische en fundamentele analyse zijn er ook methoden die trachten om beide technieken (de technische en de fundamentele analyse) te combineren om op die manier te komen tot een betere voorspellende kracht van het model (Glaeser & Gyourko, 2006; Wu & Brynjolfsson, 2015). Zo hebben onder andere Glaeser en Gyourko (2006) getracht beide methoden te combineren om zo een optimaal model voor de voorspelling van de ontwikkeling van de woningmarkt te bouwen. Zij signaleren met hun model weliswaar een trend maar slagen er niet in de waardeontwikkeling onder de meest volatiele marktomstandigheden te verklaren. Glaeser (2008) vermoedt dat dit te wijten valt aan de aanwezigheid van sentiment of zelfs irrationeel optimisme. Tse (1997) toont middels technische analyse, op basis van een

Autoregressive Integrated Moving Average model² (ARIMAmodel), aan dat er sprake is van autocorrelatie in de woningprijzen in Hong Kong. Desondanks pleit Tse te zoeken naar een model waarin zowel technische- als gedragsanalyse worden gecombineerd om meer nauwkeurig de pieken en dalen in de marktontwikkeling te kunnen voorspellen.

De aanname van Glaeser en het voorstel van Tse corresponderen met de uitkomst van het onderzoek van Shiller (2008). Shiller concludeert dat schommelingen in de woningmarkt altijd plaatsvinden onder omstandigheden waarbij substantiële psychologische aspecten een rol spelen. Het verklaren van deze schommelingen kan dus niet uitsluitend gedaan worden met behulp van de ‘klassieke’ fundamentele economische factoren (Shiller, 2008; Dietzel, 2016). Shiller baseerde zijn analyses op mediaberichten die suggereerden dat er veranderingen in de woningmarkt plaatsvonden. Destijds was hij niet in staat, omdat dergelijke data simpelweg niet bestonden, om real-time data van actuele veranderingen in het marktsentiment in zijn analyses te verwerken. Hij bewees echter desondanks dat mede op basis van deze mediaberichten pieken en dalen in de vastgoedmarkt verklaard kunnen worden.

In overeenstemming met Shillers en Glaesers visies concludeerden Dietzel et al. (2014) dat het uitgangspunt fout is dat, vanwege het enkele feit dat het onderliggende ‘sentiment’ lastig of niet meetbaar is, voorspellingen uitsluitend op fundamentele factoren gebaseerd kunnen worden (Dietzel, Braun, & Schäfers, 2014). Om zo zuiver mogelijk het sentiment te vatten in een voorspellend model zijn er veel onderzoeken verricht naar de invloed en de voorspellende kracht van consumentensentiment en –gedrag op de ontwikkeling van de woningmarkt (Weber & Devaney, 1996; Marcato & Nanda, 2014; Wang & Hui, 2016; Chun, 2017; Jin, Soydemir, & Tidwell, 2014; Garratt, 2000). Wang en Hui (2016) concluderen en benadrukken dat, vanuit een investeerdersperspectief, op de korte termijn ‘sentiment’ een goede indicator is voor de voorspelling van de prijs en het transactievolume. Wang en Hui (2016) hebben in hun analyse een sentimentindex gecreëerd op basis van data van de woningmarkt in Hong Kong tussen 1991 en 2016. Volgens hun onderzoek presteert deze sentimentindex significant beter bij de voorspelling van de woningprijs dan de normaliter geanalyseerde fundamentele factoren.

Een overgroot deel van de onderzoeken naar sentimentindicatoren is gebaseerd op analyses van diverse consumentvertrouwen- en woningmarktindices, alsmede enquêtes. Weber en Devaney (1996) baseren hun analyses op de Michigan Index of Consumer Sentiment (ICS) en de Index of Housing Sentiment (IHS), die respectievelijk het consumentenvertrouwen in het

² Een ARIMA model (Autoregressive Integrated Moving Average) maakt het mogelijk om voorspellingen uit te voeren op basis van intrinsieke data uit het verleden. Het model maakt de assumptie dat toekomstige waarden lineair afhankelijk zijn van haar eigen waarden in het verleden.

algemeen en het vertrouwen in de woningmarkt in het bijzonder weergeven. Door middel van een ARIMA-model tonen zij de toegevoegde waarde van beide indices aan bij de voorspelling van woningbouw in de Verenigde Staten ten opzichte van de klassieke fundamentele (macro-economische) indicatoren. Marcato & Nanda (2014) komen tot vergelijkbare resultaten waarmee zij onderschrijven dat diverse sentimentsindicatoren een substantiële bijdrage leveren aan de kwaliteit van de voorspelling van residentiële vastgoedprijz-ontwikkelingen. Garratt (2000) benadrukt nogmaals de toegevoegde waarde van de index van het consumentenvertrouwen bij het voorspellen van de woningprijzen en concludeert dat het consumentenvertrouwen twee derde van de variantie in de jaarlijkse groei van de woningprijzen in het Verenigd Koninkrijk verklaart. Tevens toont hij aan dat het consumentenvertrouwen de woningprijzen tot zo'n drie kwartalen van te voren kan voorspellen.

Dat het analyseren van het sentiment van toegevoegde waarde is bij de voorspelling van de ontwikkeling van de woningmarkt is meermaals bewezen. Klassieke fundamentele (macro-economische) indicatoren zijn veelvuldig “verslagen” door alternatieve methoden die gebaseerd waren op indicatoren die het sentiment in de markt wisten weer te geven (Marcato & Nanda, 2014; Weber & Devaney, 1996), dan wel aangevuld door indicatoren die het sentiment in de markt weten te duiden (Wang & Hui, 2016). Ook is meermaals bewezen dat het consumentenvertrouwen een van de beste indicatoren is om het sentiment in de markt te duiden. Ondanks deze conclusies blijft de wetenschap zoeken naar variabelen die nog actueler en nog accurater het sentiment in de markt weer weten te geven om zodoende de voorspellende kracht van het model verder te perfectioneren.

2.2 *Google Trends; Niet-vastgoed gerelateerd*

Naast het gebruik van consumenten- en marktindices als sentimentindicatoren bij de voorspelling van de woningprijs zijn er ook alternatieve databronnen die gebruikt worden. Een relatief nieuwe invalshoek is het analyseren van online zoekgedrag op Google in relatie tot ontwikkelingen op de woningmarkt. Google Trends is het online platform dat informatie bevat over de zoekintensiteit naar alle online Google zoektermen binnen een bepaald gebied in de periode vanaf januari 2004. Voor alle gewenste zoektermen kan de zoekintensiteit worden opgevraagd. Afhankelijk van de zoekfrequentie van de desbetreffende term, wordt informatie over de zoekintensiteit wekelijks dan wel maandelijks weergegeven. Eén van de bekendste onderzoeken met behulp van Google Trends is dat van Ginsbergen et al. (2009). Met hun onderzoek tonen zij een duidelijke parallel aan tussen de zoekfrequentie naar bepaalde zoektermen gerelateerd aan de thema's “verkoudheid” en “griep”, en het daaropvolgende

daadwerkelijke fysieke bezoek aan de dokter. Dit stelt Ginsbergen et al. in staat om met behulp van Google Trends-data sneller en accurater te voorspellen wanneer er een verhoogde kans is op griep epidemieën dan de gevestigde gezondheidsinstellingen (Ginsberg, et al., 2009).

De wetenschappelijke literatuur kent, als reactie op de gepubliceerde Google Trends-data en geïnspireerd door het onderzoek van Ginsberg et al., een rijke geschiedenis aan onderzoeken naar voorspellende factoren en modellen op basis van Google Trends-data (Vosen & Schmidt, 2011; Askitas & Zimmermann, 2009; Choi & Varian, 2012; Kristoufek, 2013). Askitas en Zimmerman (2009) nemen een sterke correlatie waar tussen de online zoekintensiteit op Google en de werkloosheidspercentages in Duitsland. Zij gebruiken als verklarende variabelen een index op basis van diverse Google zoektermen als 'werkloosheidsinstantie', 'werkloosheidspercentage', 'personeelsadviseur' en de namen van Duitse uitzendbureaus, vacaturewebsites en kantoren. Hiermee bewijzen zij in een vroeg stadium de toegevoegde waarde van informatie met betrekking tot internetactiviteit, en dus marktsentiment, in de voorspelling van het economisch gedrag van mensen onder complexe en veranderende omstandigheden.

Choi en Varian (2012) beschrijven hoe Google Search Insight data (nu Google Trends) benut kan worden om voorspellingen te doen over diverse economische parameters waaronder werkloosheid, autoverkoop en vakantiebestemmingen. Daarbij vergelijken zij in hun onderzoek een basismodel met uitsluitend de data van de afhankelijke variabele (ARIMA) met een model waaraan de Google zoektermen zijn toegevoegd (ARIMAX³). Hiermee tonen zij aan dat Google Trends de voorspellende kracht van de klassieke voorspellingsmethoden met 5 tot 20 procent kan verbeteren.

Vosen en Schmidt (2011) slagen er in om op basis van een ARIMAX-model aan te tonen dat Google Trends-data een kwalitatief betere bron van informatie is dan de twee meest gangbare, op enquêtes gebaseerde indicatoren (de University of Michigan Consumer Sentiment Index en de Conference Board Consumer Confidence Index). Hiermee benadrukken zij de toegevoegde waarde van het gebruik van data verkregen middels Google Trends bij het zo zuiver mogelijk weerspiegelen van het sentiment in de markt en daarmee het zo goed mogelijk voorspellen van het algemene consumptiegedrag.

Een sector waarin gebruik van voorspellende modellen met Google Trends-data een

³ Het ARIMAX model is een uitgebreide versie van het ARIMA model welke andere verklarende variabelen incorporeert. Dit model is dan ook vergelijkbaar met een multivariate regressiemodel.

dominante rol speelt is de toerismesector (Vu & Turner, 2006; Petrevska, 2017; Önder, 2017; Gawlik, Kabaria, & Kaur, 2011; Yang, Pan, Evans, & Lv, 2014). Gawlik et al. (2011) tonen op basis van data uit Hong Kong aan dat het zoekvolume van Google Trends een bruikbare voorspeller is van toerisme volumes. Hetzelfde beeld wordt bevestigd door onderzoek van Önder (2017) en Yang et al. (2014). Daar waar veel van de onderzoeken in aanpak vergelijkbaar zijn voegt Önder (2017) in zijn onderzoek een unieke invalshoek toe. Dit, door de accuraatheid van voorspellingen op stedelijk niveau te benchmarken met ontwikkelingen van het toerisme op landelijk niveau. (Önder, 2017; Mills & Skitmore, 2003) Önder (2017) alsmede Vu & Turner (2006) concluderen dat de accuraatheid van regionale en landelijke voorspellingen vergelijkbaar is.

2.3 *Google Trends; Vastgoed-gerelateerd*

De relatie tussen online zoekintensiteit en ontwikkelingen op de vastgoedmarkt is sinds het vrijgeven van de Google Trends-data, onderwerp geweest van wetenschappelijk onderzoek (Beracha & Wintoki, 2013; Van Veldhuizen, Vogt, & Voogt, 2016; Dietzel, Braun, & Schäfers, 2014; Wu & Brynjolfsson, 2009; Dietzel, 2016). Dietzel (2014) concludeert dat Google Trends data van toegevoegde waarde is bij de voorspelling van prijsontwikkelingen van commerciële vastgoedobjecten. Hiermee toont Dietzel de toegevoegde waarde aan van Google Trends als proxy voor het sentiment in de commerciële vastgoedmarkt. Later bewijzen Dietzel et al. (2016) dat hun model, waaraan Google Trends-data is toegevoegd, met 89 procent nauwkeurigheid de ontwikkeling van de woningprijzen kan voorspellen. Wu en Brynjolfsson (2009) gebruiken data van Google Trends om voorspellingen te doen van aantallen transacties en prijsontwikkelingen in de woningmarkt. Hiervoor gebruiken zij data uit 51 staten van de Verenigde Staten. Met hun onderzoek wordt, op basis van de totale zoekintensiteit binnen de Google Trends subcategorie “Vastgoed makelaars”, op overtuigende wijze de toegevoegde waarde van Google Trends aangetoond (Wu & Brynjolfsson, 2009).

Beracha en Wintoki (2013) bewijzen, door middel van een crossectionele analyse⁴, dat veranderingen van de woningprijs voorspeld kunnen worden aan de hand van online zoekmethoden en -frequenties. Hierbij maken zij onderscheid tussen krappe en ruime woningmarkten op metropoolniveau. Een nadeel van de implementatie van deze onderzoeksmethodiek is dat van Google Trends een groot aantal waarnemingen op een laag aggregatieniveau (stedelijk/metropool) vereist is. Beracha en Wintoki (2013) combineren daarom de zoekfrequentie van de termen “Vastgoed i” en “Huur i” waarbij “i” de stad of metropoolregio van een stad in de Verenigde Staten weergeeft (Beracha & Wintoki, 2013). In

⁴ Bij crossectionele analyses wordt een dwarsdoorsnede van de populatie opgenomen in een steekproef.

2015 voerde Lind een vergelijkbare analyse uit voor de Zweedse woningmarkt. Lind maakt in zijn onderzoek gebruik van een ARIMA-model. Lind baseert zijn analyse op verschillende zoektermen die het sentiment in de markt weergeven en maakt daarbij gebruik van de volgende Google Trends-zoektermen: “Hemnet” (Grootste Zweedse makelaars site), “interest rate”, “hypotheek”, “koop een appartement”, “koop een huis” en “inflatie”. Uit zijn analyse komt naar voren dat met name de zoekintensiteit naar de Google Trends zoektermen “Hemnet” en “Huis kopen” een significant effect op de ontwikkeling van de woningprijs hebben (Lind, 2015).

Dit betreffen allemaal buitenlandse onderzoeken. Er is echter weinig wetenschappelijk onderzoek verricht naar de relatie tussen online zoekgedrag en de Nederlandse vastgoedmarkt. Van Dijk en Francke (2015) hebben met behulp van gedetailleerde informatie van het zoekgedrag van bezoekers op de website van Funda aangetoond dat het aantal clicks op een online aangeboden vastgoedobject een goede indicator is voor de vraag naar dat type vastgoed (Van Dijk & Francke, 2015). Het onderzoek van Van Veldhuizen et al. (2016) komt sterk overeen met dit onderzoek. Zij hebben met behulp van de zoekterm ‘Hypotheek’ aangetoond dat Google zoektermen van een voorgaande maand een sterke relatie vertonen met het aantal woningtransacties in de daaropvolgende maand (Van Veldhuizen, Vogt, & Voogt, 2016). Een analyse van de relatie tussen diverse Google zoektermen en de ontwikkeling van de Nederlandse woningprijzen ontbreekt in de huidige literatuur.

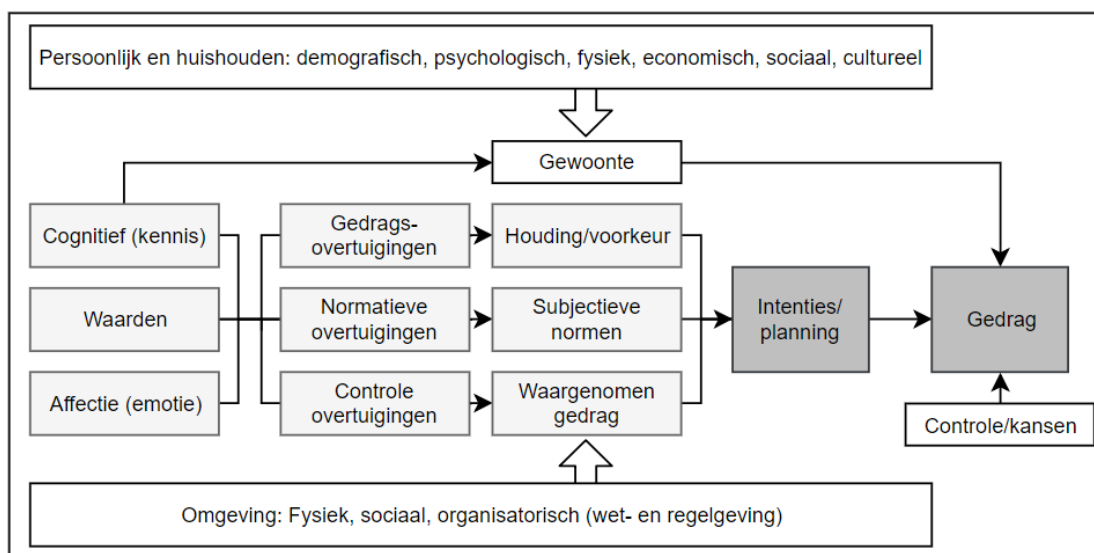
2.4 *Google Trends; zoektermen*

Om het sentiment in de markt goed te kunnen kwantificeren is het van belang dat de juiste Google zoektermen geanalyseerd worden. Het is van belang om het (online) zoekgedrag van een woning(ver)koper voorafgaand aan een transactie te doorgronden. Aangezien dit sterk afhankelijk is van het gedrag van consumenten onder bepaalde (economische) omstandigheden heeft dit onderzoek ook raakvlakken met de gedragswetenschappen. De aan- en verkoop van een woning is immers geen ad hoc beslissing, maar een weloverwogen en geplande keuze. Een analyse van dit proces is daardoor relevant voor dit onderzoek.

Eén van de meest invloedrijke theorieën binnen de gedragswetenschappen is de ‘Theorie van gepland gedrag’ (*Theory of planned behaviour*) (Ajzen, 1991), een uitbreiding van de ‘Theorie van beredeneerde actie’ (*Theory of reasoned action*). Ontwikkeld door Fishbein & Ajzen in 1980. Resumerend staat in deze theorie centraal dat het gedrag van mensen beïnvloed wordt door diverse factoren (Ajzen, 1991). Het is een bewezen theorie in het voorspellen van intenties en daaropvolgend gedrag (AL-Nahdi, Habib, & Albdour, 2015). Om dit model

toepasselijk te maken voor de analyse en de verklaring van het (ver)koopgedrag binnen de vastgoedmarkt heeft, zoals weergegeven in figuur 1, Heijs (2006;2007), aan het model diverse elementen toegevoegd. Te weten: gewoonten, persoonskenmerken (*personal and household*) en omgeving (*environment*) (Verbruggen & Heijs, 2017). Met name deze toevoegingen zijn relevant voor het theoretisch onderzoek naar de Google zoektermen die van belang zijn om de voorspellende kracht van het model te maximaliseren.

Voorafgaand aan de woningtransactie zal het waarnemen van de intentie om over te gaan tot koop of verkoop een goede indicator zijn voor de waarschijnlijk daaropvolgende daadwerkelijke transactie. En dus zal die intentie het sentiment in de markt weergeven. (AL-Nahdi, Habib, & Albdoor, 2015). De intentie wordt gedreven door gewoonten en sociale opvattingen welke gebaseerd zijn op onder andere diverse macro-economische en sociale aspecten. Zoals in voorgaand hoofdstuk reeds vermeld zijn deze fundamentele factoren dan ook onderwerp van veel wetenschappelijk onderzoek (De Vries, 2010; Égert & Mihaljek, 2007). De toegevoegde waarde van dit onderzoek is het vinden en het verklaren van die zoektermen die het sentiment direct voorafgaand aan de daadwerkelijke gedraging zo zuiver mogelijk weerspiegelen. De laatstgenoemde factor uit het model van Azjen (1991) betreft *controle*. In de controlefase wordt getoetst of het geplande gedrag daadwerkelijk realistisch is en ook daadwerkelijk uitgevoerd kan worden. Gibler en Nelson (1998) refereren hierbij aan het wel of niet verkrijgen van een geschikte hypotheek. Dit biedt houvast voor de mogelijk interessante Google Trends-termen.



Figuur 1. Model van Azjen (1991) met aanvullingen van Heijs (2006;2007), licht grijze vlakken niet relevant, eigen bewerking

Afgeleid van het model van Azjen en de aanvullingen van Heijs is het van belang om in het transactieproces de volgende fases te onderscheiden: de intentie om te (ver)kopen, de daadwerkelijke gedraging (koop of verkoop) en zoektermen gerelateerd aan de controle daarvan. Met inachtneming van deze kennis is onderzocht welke analysemethoden en zoektermen op het gebied van Google Trends in de wetenschappelijke literatuur zijn behandeld. In Bijlage A is een overzicht te vinden van de geraadpleegde bronnen. Uit deze analyse is gebleken dat naast verschillen in de gehanteerde onderzoeksmethodiek en het gehanteerde statistische model, er ook verschillen bestaan in het gebruik en de toepassing van Google Trends-termen. In de literatuur wordt gebruik gemaakt van de Google Trends-datareeksen van losse zoektermen, combinaties van zoektermen of door Google geformuleerde categorieën. Om de data zo min mogelijk te manipuleren en de originele data te waarborgen wordt in dit onderzoek gefocust op losse zoektermen of door Google samengestelde categorieën (Van Veldhuizen, Vogt, & Voogt, 2016; Wu & Brynjolfsson, 2009; Lind, 2015). In tabel 1 zijn de termen geformuleerd die, rekening houdend met eerder onderzoek en hun theoretische achtergrond, mogelijk een goede proxy voor het sentiment binnen de markt kunnen bieden. Termen die in Google Trends weinig tot geen activiteit vertonen zijn niet meegenomen in de analyse.

Tabel 1. De 13 Google Trends termen

Google Trends Termen	Beredenering
Onroerend goed (dit betreft een gehele, door Google Trends samengestelde, categorie op basis van zoektermen gerelateerd aan “onroerend goed”) Vastgoed	Algemene termen met betrekking tot (activiteit op) de vastgoedmarkt, niet specifiek voor de woningmarkt.
Makelaar Funda	Termen gerelateerd aan het faciliterende medium in de transactie. Met name kenmerkend voor de intentie om te (ver)kopen.
Huis kopen Woning kopen Huis verkopen	Termen gerelateerd aan vraag en aanbod en de intentie om over te gaan tot (verkoop).
Huis te koop	Term die zowel een proxy zou kunnen zijn vanuit de vraag als aanbod zijde.
Hypotheek Hypotheekrente Rente Maandlasten (gerelateerd aan hypotheek) Hypotheek berekenen	Termen gerelateerd aan de financiering/hypotheek van een woning (controle stap in model van Azjen en aanvulling van Heijs).

2.5 Hypotheses

Op basis van de literatuurstudie zijn een drietal hypotheses geformuleerd. Uit diverse onderzoeken is gebleken is dat Google Trends data van toegevoegde waarde is in de voorspelling van diverse factoren en binnen diverse landen. Ook voor de vastgoedmarkt, en specifiek de woningmarkt, zijn er diverse onderzoeken waaruit de voorspellende kracht van Google Trends data is gebleken. Aldus zijn de volgende hypotheses ontstaan:

Hypothese 1: Google Trends data is van toegevoegde waarde bij de voorspelling van de woningprijzen in Nederland.

Uit een analyse van de wetenschappelijke literatuur over de relatie tussen sentiment-indicatoren in relatie tot woningmarktvoorspellingen blijkt dat het consumentenvertrouwen een goede voorspeller is. Gebleken is dat Google Trends-data een betere voorspeller is dan het consumentenvertrouwen. De tweede en derde hypothese vloeien voort uit deze constatering.

Hypothese 2: Het consumentenvertrouwen is van toegevoegde waarde in de voorspelling van de woningprijzen.

Hypothese 3: Met behulp van Google Trends-zoektermen kan een meer nauwkeurige voorspelling van de woningprijzen worden gedaan dan door middel van het opnemen van het consumentenvertrouwen.

3. Data en methodologie

3.1 Data

De afhankelijke variabele in dit onderzoek betreft de gemiddelde woningprijs in Nederland in de periode januari 2004 tot en met januari 2018. Data omtrent woningprijzen in Nederland is publiekelijk toegankelijk en te downloaden via de website van het Kadaster. Ter bevordering van de interpretatie zijn alle datareeksen getransformeerd naar een index, zo ook de Woningprijzen. De woningprijs is getransformeerd naar een woningprijsindex door waarden te delen door de hoogste woningprijs. Alle variabelen, zowel de verklarende (Google Trends termen en consumentenvertrouwen) als ook de te verklaren parameter (woningprijzen), zijn met een maandelijkse frequentie in de modellen verwerkt.

Google Trends Data

In Nederland is het marktaandeel van Google, wat betreft het gebruik van zoekmachines op internet, met circa 90 procent het grootst (Borger, 2018). Wereldwijd bedraagt de marktpenetratie van Google gemiddeld ruim 72 procent (NetMarketschare, 2018). Jun et al. (2017) nemen het afgelopen decennia een sterke groei in het gebruik van Google Trends waar en zien dat het aantal onderzoeksgebieden waarbij van haar data gebruik gemaakt wordt toenemen. Jun et al. voorzien een toename in onder andere geografie en planning & ontwikkeling. De data is publiekelijk toegankelijk en geeft vanwege de omvang en de mate van marktpenetratie het vertrouwen dat deze voldoende representatief zijn voor het online zoekgedrag van woningvragers en -aanbieders, en daarmee dus ook voor het sentiment binnen de woningmarkt.

Voor deze studie is gebruik gemaakt van de Google Trends-database welke publiekelijk beschikbaar is. Deze database bevat informatie over de zoekintensiteit naar bepaalde zoektermen binnen een bepaald gebied in de periode vanaf januari 2004. Voor alle gewenste zoektermen kan de zoekintensiteit worden opgevraagd en gratis gedownload worden. Afhankelijk van de zoekfrequentie van de desbetreffende zoekterm, wordt informatie over de zoekintensiteit wekelijks dan wel maandelijks weergegeven. Binnen de database kan data geselecteerd worden op basis van de desgewenste geografische schaalniveau (Landelijk, provincie, metropool). De data wordt geografisch gefilterd op basis van het betreffende IP-adres. Het laagst mogelijke schaalniveau binnen Nederland is de provincie. Tevens kan ook gezocht worden binnen een bepaalde categorie, bijvoorbeeld 'onroerend goed'. In deze categorie worden de zoekresultaten die gerelateerd zijn aan deze categorie gecombineerd weergegeven. Het voordeel van Google Trends is dat het grote hoeveelheden data verzamelt, verwerkt en het mogelijk maakt om deze data gratis te analyseren (Jun, Yoo, & Choi, 2017).

Google Trends-data geeft geen absolute cijfers maar een index die weergeeft hoe vaak er gezocht is naar een bepaalde term ten opzichte van het totaal aantal zoektermen binnen het gehanteerde (geografische) schaalniveau. De frequentie wordt weergegeven op een schaal van 0 tot 100. Op die manier weerspiegelen de data het sentiment in een bepaald gebied naar een bepaalde term of bepaald thema. En dus niet de absolute frequentie. De achterliggende formule van de Google Trends Index ziet er als volgt uit:

Google Trends Index

$$= \frac{\text{Frequentie zoekterm 'x' op moment 't' binnen locatie 'z'}}{\text{Frequentie totaal aantal zoektermen op moment 't' binnen locatie 'z'}}$$

Consumentenvertrouwen

Zoals blijkt uit de theorie van Azjen (1991) en diverse andere onderzoeken (Garratt, 2000; Weber & Devaney, 1996; Chun, 2017) is het consumentenvertrouwen een belangrijke indicator voor het meten van het sentiment in de markt. In dit onderzoek wordt dan ook de vergelijking gemaakt in de voorspellende kracht tussen zowel het consumentenvertrouwen en Google Trends data. Op deze manier wordt getracht de voorspellende kracht van beide indicatoren inzichtelijk te maken en eventuele onderlinge verbanden te ontdekken. Data met betrekking tot het consumentenvertrouwen wordt op maandelijkse basis gepubliceerd door het Centraal Bureau van Statistiek (CBS) en is publiekelijk toegankelijk en te downloaden. Het consumentenvertrouwen is gebaseerd op het oordeel van consumenten en wordt getoetst op door middel van van 5 deelvragen. Consumenten worden gevraagd hun oordeel te vellen over de financiële situatie in (1) de afgelopen en (2) de komende 12 maanden, (3) of ze het een gunstig moment vinden voor het doen van grote aankopen (bijvoorbeeld huizen). Vervolgens wordt hen gevraagd naar hun kijk op de economische situatie van (4) de afgelopen- en (5) de komende 12 maanden. Het consumentenvertrouwen is het rekenkundig gemiddelde van deze 5 vragen (CBS, 2018). Ook de datareeks van het consumentenvertrouwen wordt getransformeerd van absolute gegevens naar een index. Dit, ten behoeve van een betere vergelijkbaarheid met andere variabelen en de interpretatie daarvan.

3.2 ARIMA/ARIMAX

Een gebruikelijke methode bij onderzoek naar de voorspellende kracht van een variabele is het toepassen van de Box-Jenkins methode (Box & Jenkins, 1976) oftewel een ARIMA model (Chmyznikov & Galvanauskas, 2013; Lind, 2015; Vosen & Schmidt, 2011). Jun et al. (2017) hebben op basis van een netwerkanalyse over 657 research papers onderzoek gedaan naar trends in de studies waarin de afgelopen 10 jaar is gebruik gemaakt is van Google Trends. Uit dit onderzoek is onder andere gebleken dat de ARIMA methode in veel Google Trends-gerelateerd onderzoek genoemd wordt en een vaak toegepaste methode is voor onderzoek op basis van Google Trends-data (Jun, Yoo, & Choi, 2017). ARIMA modellen hebben door de jaren heen bewezen dat zij met grote regelmaat beter presteren dan de meer complexe economische modellen (Levenbach, 2017). Tevens zijn ARIMA modellen uitermate geschikt voor korte termijn voorspellingen (Tse, 1997).

Overeenkomstig met vergelijkbaar onderzoek zullen verschillende modellen gecreëerd worden die vergeleken worden met een basis model, om te toetsen of er een verbetering optreedt in de voorspellende kracht (Dietzel, Braun, & Schäfers, 2014; Vosen & Schmidt, 2011). In het basismodel wordt het ARIMA-model slechts toegepast op de woningprijs (Vosen & Schmidt, 2011). Aan het tweede model zullen diverse Google Trends zoektermen worden toegevoegd om erachter te komen welke variabele het beste de woningprijzen voorspelt. Het derde model zal bestaan uit het basismodel met daaraan toegevoegd het consumentenvertrouwen. Tot slot zal door middel van model 4 gekeken worden naar wat de toegevoegde waarde van Google trends is ten opzichte van het consumentenvertrouwen door model één, twee en drie te combineren. Door de voorspellende kracht van de modellen met elkaar te vergelijken kan de toegevoegde waarde van Google Trends beoordeeld worden.

Het ARIMA-model bestaat uit drie onderdelen, te weten: het Autoregressive (AR) deel (of $AR(p)$), het differentiatie deel (I) en het Moving Average (MA) (of $MA(q)$)deel (Makridakis & Hibon, 2011). Door verklarende variabelen aan het ARIMA model toe te voegen kan de invloed en de voorspellende kracht van de betreffende zoekterm worden onderzocht. Met de toevoeging van de verklarende variabelen verandert de naam van ARIMA-model in een ARIMAX-model.

Autoregressive model

Het meest eenvoudige statistische time series model is een nummer één “autoregressive model” (zelfvoorspellend model), of $AR(1)$ model. Dit houdt in dat een variabele in een tijdreeks afhankelijk is van zijn eigen waarde in de voorgaande periode. Een generalisatie van

dit model wordt aangeduid met AR(p). Een AR(2) model is dus logischerwijs een autoregressive model van de tweede orde, dus twee perioden terug. De formule luidt:

$$Y_t = \sum_{i=1}^p \phi_i Y_{t-i} + \mu_t \quad (1.1)$$

Waarbij:

Y_t = Afhankelijke variabele (Woningprijzen in Nederland)

$\phi_i Y_{t-i}$ = Lag i van de verklarende parameter van het auto regressieve deel op tijdstip t

μ_t = Foutterm

t = Factor tijd

Het Moving Average model

Het meest eenvoudige Moving Average model, MA(1) model houdt in dat Y_t afhankelijk is van de waarde van de foutterm in de voorgaande periode. Ook hier geldt dat de lagterm (vertragingstermijn) groter dan één kan zijn. De formule luidt:

$$Y_t = \mu_t + \sum_{j=1}^q \phi_j \mu_{t-j} \quad (1.2)$$

Waarbij:

Y_t = Afhankelijke variabele (Woningprijzen in Nederland)

$\phi_j \mu_{t-j}$ = Lag j van de foutterm van het auto regressieve deel op tijdstip t

μ_t = Foutterm

t = Factor tijd

Differentiatie

Een ARIMA model is een uitbreiding van het ARMA model. Een ARMA model kan enkel toegepast worden op een tijdreeks Y_t als deze stationair is. Dit betekent dat het gemiddelde, de variantie en de covariantie constant zijn over de tijd (Brooks & Tsolacos, 2010). Echter, de meeste economische en financiële tijdreeksen en zeker ook de vastgoedmarkt, zijn cyclisch en/of onderworpen aan een trend (Makridakis & Hibon, 2011). Doormiddel van bijvoorbeeld een Dickey Fuller test kan achterhaald worden of de data stationair is. De formule van een eenmalig gedifferentieerde tijdreeks luidt:

$$\Delta Y_t = Y_t - Y_{t-1} \quad (1.3)$$

Waarbij:

ΔY_t = Eerste orde gedifferentieerde afhankelijke variabele

$Y_t - Y_{t-1}$ = Het verschil tussen opeenvolgende observaties

t = Factor tijd

Als blijkt dat de nieuwe tijdreeks stationair is dan wordt dit omschreven als I(1) en verklaart daarmee de 'I' in ARIMA. Mocht de tijdreeks na het opnieuw uitvoeren van de Dickey Fuller

test desondanks niet stationair zijn, dan kan deze opnieuw gedifferentieerd worden, totdat deze alsnog stationair bevonden wordt. De formule luidt:

$$\Delta\Delta Y_t = \Delta^2 Y_t = \Delta Y_t - Y_{t-1} \quad (1.4)$$

Waarbij:

$\Delta\Delta Y_t$ = Tweede orde gedifferentieerde afhankelijke variabele

$\Delta^2 Y_t$ = Het verschil van het verschil tussen opeenvolgende observaties

t = Factor tijd

Voorspellende kracht

Het doel van dit onderzoek is het in beeld brengen en analyseren van de toegevoegde waarde van Google trends in voorspellingen met betrekking tot de ontwikkelingen van de vastgoedmarkt. Het is dus van belang om de voorspellende kracht van de diverse modellen te toetsen. Op basis van de ARIMA en ARIMAX modellen kan een voorspelling gedaan worden. De kwaliteit van het model en de voorspellende kracht daarvan wordt vervolgens beoordeeld door middel van een (with)In-sample voorspelling waarbij gekeken wordt naar de afwijking van de voorspelling ten opzichte van de daadwerkelijke waarde.

Een berekening die het mogelijk maakt om de voorspellende kwaliteit te bepalen en een vergelijking te maken tussen de diverse modellen is de Mean Square Error (MSE) (Brooks & Tsolacos, 2010). De MSE kwadrateert het verschil tussen de voorspelde en de daadwerkelijke waarde en legt daarbij dus de nadruk op de variantie van de voorspelling (Dietzel, Braun, & Schäfers, 2014). De formule luidt:

$$MSE = \frac{1}{n} \sum_{i=1}^n \hat{e}_i^2 \quad (1.5)$$

Waarbij:

n = Het aantal observaties

\hat{e}_i = Afwijking tussen de voorspelde (A) en de daadwerkelijke waarde (F).

4. Resultaten

4.1 Totstandkoming basismodel

De totstandkoming van het basismodel (ARIMA) bestaat uit een vijftal fasen: (1) indien nodig de data transformeren tot stationaire data (2) de (grafische) inschatting van het model (3) de schatting van de parameters van het model en (4) de model diagnostiek en tot slot (5) een beoordeling van de voorspellende kracht van de modellen (Brooks & Tsolacos, 2010). De totstandkoming van het ARIMA model is echter iteratief en komt door middel van ‘trial and error’ tot stand (Tse, 1997).

Stationariteit

Een belangrijke assumptie voor het ARIMA-model is dat de data stationair zijn en geen Unit Root bevat. Een stationaire dataset of een dataset zonder Unit Root wordt gekenmerkt door een constant gemiddelde, een constante variantie en een constante autocorrelatie structuur (Brooks & Tsolacos, 2010). Om te testen of de data voldoet aan deze eis kunnen diverse toetsen worden toegepast. Twee veelgebruikte testmethoden zijn de Dickey-Fuller (DF) test en de Augmented Dickey-Fuller (ADF) test (Tse, 1997). De ADF is een uitbreiding van de standaard test en maakt het mogelijk om niet enkel de stationariteit op tijdstip $t=0$ te analyseren maar kunnen ook de lags⁵ van de desbetreffende variabele worden getest op stationariteit (Dickey & Fuller, 1981; Brooks & Tsolacos, 2010). Gezien het doel van dit onderzoek en het feit dat ook in het ARIMA model diverse lags toegevoegd zullen worden is ervoor gekozen om voor iedere variabele de uitgebreide ADF test, toe te passen (Tse, 1997; Chmyznikov & Galvanauskas, 2013; Dietzel, Braun, & Schäfers, 2014). Er zijn diverse manieren waarop de gehanteerde lags in de ADF test gekozen kunnen worden. De keuze voor de ene of andere manier is echter vaak arbitrair. Gezien het feit dat het in dit geval om maandelijkse data gaat, pleiten Brooks en Tsolacos (2010) voor het kiezen van een lag van 3 maanden (kwartaal) of 12 maanden. Voor beide testen geldt dezelfde nulhypothese, te weten:

H_{0b}: De geanalyseerde tijdreeks variabele is niet stationair

H_{0a}: In de geanalyseerde tijdreeks variabele is een Unit Root aanwezig

De ADF test is gebaseerd op een t-verdeling, dit betekent dat indien de test statistic hoger is dan de kritische waarde, de nulhypothese verworpen kan worden. In dat geval wordt de variabele stationair bevonden en is er geen Unit Root aanwezig. Hierbij kan onderscheid

⁵ Een lag, of in het Nederlands ‘vertragsingsfactor’ geeft de historische datareeks weer. Binnen dit onderzoek wordt gesproken over lags en betreft, tenzij anders vermeld, een maandelijkse frequentie. Een lag van 1 betreft de waarde van de datareeks op tijd(t)-1 oftewel de data van de voorgaande maand.

gemaakt worden in de geprefereerde betrouwbaarheidsinterval. In dit onderzoek wordt uitgegaan van het gebruikelijke betrouwbaarheidsinterval van 95 procent (p-waarde <0,05). In een aantal gevallen vertonen lag 3 en 12 een significante afwijking en is voor de zekerheid de Philips-Perron test toegepast. Dit is een tweede test die naast de Dickey Fuller test veelal toegepast wordt om te testen of er een Unit Root aanwezig is (Phillips & Perron, 1988; Brooks & Tsolacos, 2010; Petrevska, 2017). De nulhypothese is ook gelijk aan die van de ADF test. Indien minimaal 2 van de 3 testen binnen de ADF test niet-significant zijn bevonden wordt per definitie de eerste orde gedifferentieerde waarde genomen (Brooks & Tsolacos, 2010).

Zoals af te lezen aan tabel 2 worden enkel de primaire datareeksen van de Google Trends termen ‘huis kopen’, ‘huis verkopen’, ‘woning kopen’ en ‘maandelijkse lasten’ stationair bevonden. Alle andere variabelen zijn uitsluiten na het differentiëren van de data stationair bevonden.

Tabel 2. Resultaten Augmented Dickey Fuller en Phillips Perron test

Variabele/lag	<i>Onbewerkte data</i>				Actie	<i>Bewerkte data</i>			
	Augmented Dickey Fuller (ADF)			Pperron voor Dif.		Augmented Dickey Fuller (ADF)			Pperron na Dif.
	0	3	12		0	3	12		
Koopprijs	1,80	0,70	1,69	no	1st Dif.	16,75***	7,66***	2,05	***
wrd Funda	3,57**	2,33	2,76	no	1st Dif.	13,85***	10,48***	2,79	***
wrd Hypotheekrente	4,75***	3,14	2,88	**	1st Dif.	17,00***	8,53***	3,97**	***
wrd Hypotheek	4,22***	2,49	1,24	***	1st Dif.	16,00***	10,55***	3,60**	***
wrd Huis te koop	3,97***	2,82	1,32	no	1st Dif.	14,61***	10,77***	3,52**	***
wrd Makelaar	6,70***	2,60	0,34	no	1st Dif.	19,80***	9,50***	4,82***	***
wrd Huis kopen	6,68***	3,81**	0,26	***	geen	n.v.t.	n.v.t.	n.v.t.	n.v.t.
wrd Huis verkopen	10,55***	7,22***	2,8	***	geen	n.v.t.	n.v.t.	n.v.t.	n.v.t.
wrd Woning kopen	8,78***	3,78**	0,71	***	geen	n.v.t.	n.v.t.	n.v.t.	n.v.t.
wrd Rente	4,23***	2,86	2,19	***	1st Dif.	18,57***	7,73***	3,26*	***
wrd Maandelijkse lasten berekenen	8,84***	3,86	1,73	***	geen	n.v.t.	n.v.t.	n.v.t.	n.v.t.
wrd Hypotheek berekenen	5,90***	3,03	2,39	no	1st Dif.	14,98***	11,40***	4,55***	***
wrd Vastgoed	8,02***	4,57***	2,07	*	1st Dif.	21,76***	11,90***	4,11***	***
Cat. Onroerend goed	3,50**	1,80	0,68	no	1st Dif.	17,12***	10,91***	4,27***	***
Consumentenvertrouwen	1,07	1,97	1,887	no	1st Dif.	7,84***	5,22***	3,57***	***


Note: *** $p < 0,01$, ** $p < 0,05$, * $p < 0,1$, wrd = woord, Cat.=categorie

Optimale lags


De volgende stap in de totstandkoming van het juiste model is het vinden van de juiste lag termijnen voor de AR(p) en de MA(q)-term (Brooks & Tsolacos, 2010; Tse, 1997; Lind, 2015; Petrevska, 2017). Dit wordt gedaan door de mate van autocorrelatie te bepalen; welke historische data van de woningprijsindex is gecorreleerd met de huidige waarde. Een indicatie van de juiste lag wordt verkregen door middel van twee correlogrammen, de Autocorrelation Function (ACF) en de Partial Autocorrelation Function (PACF).

De ACF biedt een indicatie van de meest geschikte Moving Average of MA(q) term en de PACF biedt een indicatie voor de meest geschikte autocorrelatie-component of AR(p) binnen het ARIMA model. Bij de ACF wordt de autocorrelatie per maand in het verleden bekeken om de optimale lag termijn te bepalen. De PACF controleert hetzelfde maar houdt rekening met tussenliggende lag-termijnen en corrigeert daarvoor. De grijze vlakken in de geplote correlogrammen in figuren 2 en 3 geven de 95 procent betrouwbaarheidsinterval weer. Pieken buiten deze bandbreedte duiden mogelijk op autocorrelatie, waarmee rekening gehouden dient te worden in het op te stellen model. Beide figuren kunnen dus als volgt geïnterpreteerd worden: Indien er in de correlogrammen een positieve piek waargenomen wordt (buiten het grijze vlak) in bijvoorbeeld lag 3 dan kan dit een indicatie zijn van een positieve correlatie tussen de woningprijsindex in een bepaalde maand en de woningprijsindex 3 maanden eerder.

De ACF biedt een indicatie van de meest geschikte Moving Average of MA(q) term. In figuur 2 is met name een afwijking te zien voor de eerste lag waarbij de correlatiecoëfficiënt significant negatief afwijkt van nul. Ook lag 6, 7 en 9 wijken, in mindere mate, significant af van nul. De PACF geeft een indicatie voor het meest geschikte autocorrelatie-component of AR(p) binnen het ARIMA model.



Figuur 2 PACF – Gedifferentieerde Woningprijs



Figuur 3 ACF – Gedifferentieerde Woningprijs

Figuur 3 laat zien dat op basis van een betrouwbaarheidsinterval van 95 procent de eerste twee lags van de correlatiecoëfficiënten significant negatief afwijken van nul. Gevolgd door een positieve piek bij lag 6 en een negatieve significant afwijkende waarde bij lag 24. Verder is af te lezen dat de data na het nemen van de eerste orde afwijking geen noemenswaardige trend kent (Brooks & Tsolacos, 2010). Ondanks dat de ACF en PACF goede indicaties bieden, benadrukken Brooks en Tsolacos (2010) dat het gebruik van grafische plots als de ACF en PACF kan leiden tot een vertekend beeld van de werkelijkheid. Datareeksen vertonen immers slechts zelden een simpel te interpreteren en juist patroon. Een goede en veelgebruikte methodiek die aanvullend toegepast wordt om de optimale lag-termijn te bepalen is het gebruik van *informatie criteria-testen*.

Gangbare informatie criteria testen zijn de Akaike's (1974) information criterion (AIC) en de Schwarz's (1978) Bayesian information criterion (BIC) (Makridakis & Hibon, 2011; Brooks & Tsolacos, 2010; Chmyznikov & Galvanauskas, 2013; Dietzel, 2016). De AIC en BIC schatten de relatieve kwaliteit van statistische modellen in. De AIC en BIC zeggen echter niets over de absolute kwaliteit van een model maar kunnen wel toegepast worden in de vergelijking met andere modellen. De keuze voor het beste model wordt gebaseerd op de kleinste waarde van bovengenoemde testen. Het verschil tussen beide testen is dat de BIC rekening houdt en corrigeert voor het aantal meegenomen parameters in een model. Wat betreft de keuze voor de AIC of BIC kan gesteld worden dat geen van beide testen superieur is aan de andere (Brooks & Tsolacos, 2010). Binnen dit onderzoek ligt de focus op de BIC-waarde.

Gezien het eerder genoemde feit dat de ACF en PACF niet altijd goed de optimale lag weergeven zijn naast de genoemde significant afwijkende lags ook de lag vóór en ná de significante lag meegenomen in de informatiecriteria-analyse. Dit resulteert in negen mogelijke AR(p)-termen maal acht mogelijke MA(q)-termen, in totaal zijn er dus 72 modellen getest⁶. Naast de AIC en BIC score is ook de significantie van de AR en MA lagterms relevant. In Bijlage B zijn alle 72 uitkomsten van de informatie criteria gepresenteerd.

In tabel 3 zijn de best scorende combinaties van AR en MA termen weergegeven waarbij rekening is gehouden met beide richtlijnen van de AIC en BIC criteria. De modellen ARIMA(1,1,2), ARIMA(3,1,1), ARIMA(5,1,5) functioneren goed. Uit deze analyse blijkt ook dat het ARIMA(2,1,2) model het beste presteert. Alle AR en MA termen van het model zijn significant binnen een 99 procent betrouwbaarheidsinterval en de AIC en BIC vertonen de

⁶Indicatie van de PACF voor de significante lags: 1, 6, 7, 9, en de eerste lag voor en na deze lags: 2, 5, 8, 10, in totaal dus acht. Indicatie van de ACF voor de significante lags: 1, 2, 6, 24 en de eerste lag voor en na deze lags: 3, 5, 7, 23, 25 in totaal dus negen, $9 \cdot 8 = 73$,

laagste waarde ten opzichte van de andere modellen. Beide constatering onderbouwen dat het ARIMA(2,1,2)-model het beste functioneert. Dit is opvallend, aangezien de ACF en PACF hier niet direct op wezen. Toch ligt deze constatering wel in lijn met de eerder genoemde kritiek op de ACF en PACF-functie (Brooks & Tsolacos, 2010).

Tabel 4 toont de resultaten van het ARIMA(2,1,2)-model. De woningprijsindex is met een positieve coëfficiënt van 0,88 significant gecorreleerd met hun eerste lag, oftewel de AR(1)-term. Dit betekent dat indien woningprijsindex tussen twee maanden met één toeneemt zal de woningprijsindex in de volgende periode met circa 0,88 toenemen. De ontwikkeling van de woningprijzen wordt dus voor circa 88 procent bepaald door de ontwikkeling van de woningprijs in de voorgaande maand (zowel positief als negatief). Dit ligt in lijn met de actuele literatuur op het gebied van positieve correlaties tussen woningprijzen (Beracha & Wintoki, 2013). De negatieve AR(2) coëfficiënt is te verklaren door het feit dat de woningprijzen zijn gedifferentieerd en dus een gemiddelde van nul kennen. Hierdoor wisselen positieve ontwikkelingen zich af met negatieve. Alle AR en MA termen van het model zijn significant binnen een 99 procent betrouwbaarheidsinterval.

Tabel 3. Resultaten AIC en BIC test

ARIMA Model	AR	MA	AIC	BIC
(1,1,1)	no	*	664.1849	676.6807
(1,1,2)	***	***	664.1825	679.8023
(1,1,8)	***	4/8	653.4868	687.8504
(2,1,2)	***	***	657.2388	675.9826
(2,1,6)	***	4/6	657.8903	689.13
(2,1,8)	1/2	4/8	653.2405	690.7281
(3,1,1)	***	***	665.3047	684.0484
(3,1,2)	1/3	1/2	663.9842	685.852
(5,1,5)	***	***	654.5338	692.0214
(5,1,6)	***	4/6	653.7867	691.2743
(6,1,5)	5/6	4/6	653.8743	691.3619

Note: *** $p < 0,01$, ** $p < 0,05$, * $p < 0,1$, de (x/y)-scores = significante resultaten van AR of MA termen

Tabel 4. Uitkomsten basismodel ARIMA(2,1,2)

D.Gem_koop	Coef.	OPG Std. Err.	z	P>[z]	[95% Conf. Interval]	
<i>ARMA</i>						
AR (L1)	0,880	0,117	7,50	0,000***	0,650	1,110
AR (L2)	-0,642	0,087	-7,41	0,000***	-0,812	-0,472
MA (L1)	-1,210	0,085	-14,17	0,000***	-1,377	-1,043
MA (L2)	0,844	0,0749	11,27	0,000***	0,697	0,990
Number of obs	168					
Wald chi2(4)	570,33					
Prob > chi2	0,000***					

Note: *** $p < 0,01$, ** $p < 0,05$, * $p < 0,1$

4.2 Toevoeging verklarende variabelen

Nu het basismodel (model 1) tot stand is gekomen kan geanalyseerd worden of, en zo ja welke, (lags van de) Google Trends termen een significante bijdrage leveren in de voorspelling van de ontwikkeling van de woningprijzen in Nederland. Ook wordt de relatie tussen het consumentenvertrouwen en de woningprijsindex getoetst. Door de toevoeging van de verklarende variabelen wordt vanaf heden voor de modellen 3 tot en met 4 gesproken van het ARIMAX⁷ model. Tabel 5 weergeeft de uitkomsten van de vier modellen die tot stand zijn gekomen.

Model 2 toont de best presterende uitkomsten van een analyse van het effect van de dertien Google Trends termen. De aankoop van een woning is geen impulsaankoop en dus wordt niet alleen data op tijdstip nul toegevoegd. Ook de lags van de dertien Google Trends termen tot elf perioden terug zijn stapsgewijs aan het basis model toegevoegd. Uit deze analyse is gebleken dat diverse Google Trends termen goede resultaten bieden. Ze tonen zowel (1) een lage, en dus goede AIC en BIC score, (2) significante resultaten voor de AR(p) en MA(q)-termen en (3) de Google Trends termen of de lags daarvan vertonen significante resultaten. De zoektermen die een significant effect op de woningprijsindex op tijdstip t=0 hebben zijn: Funda (lag 5 en 6), Hypotheek (lag 1), Huis kopen (lag 2 en 5) en Maandelijkse lasten (lag 6).

Om de robuustheid en kwaliteit van de diverse modellen te testen/waarborgen zijn naast het ARIMAX(2,1,2) model ook de drie eerder genoemde goed presterende ARIMA modellen toegepast (ARIMA(1,1,2) ARIMA(3,1,1), ARIMA(5,1,5)). De robuustheid is getest door de modellen te onderwerpen aan aanpassingen van het basis model. Uit deze test is gebleken dat het model waaraan de 5^e en 6^e lag van het woord ‘Funda’ is toegevoegd over het algemeen het beste presteert en blijvend significante resultaten vertoont (model 3).

Tabel 5. Uitkomsten Modellen 1 t/m 4

	Model 1		Model 2		Model 3		Model 4	
	Coef.	p-value	Coef.	p-value	Coef.	p-value	Coef.	p-value
Funda t-5			.066	0.043**			.058	0.065*
Funda t-6			.065	0.034**			.064	0.028**
Vertr. t-8					.058	0.043**	.044	0.116
<i>ARMA</i>								
AR (L1)	.880	0.000***	.819	0.000***	1.151	0.000***	1.085	0.000***
AR (L2)	-.642	0.000***	-.573	0.000***	-.213	0.217	-.149	0.380
MA (L1)	-1.210	0.000***	-1.188	0.000***	-1.522	0.000***	-1.482	0.000***
MA (L2)	.844	0.000***	.810	0.000***	.604	0.000***	.567	0.000***
Observaties	168		162		160		160	

Note: Afkorting “Vertr” betreft de variabele consumentenvertrouwen, *** $p < 0,01$, ** $p < 0,05$, * $p < 0,1$

⁷ De toevoeging van de ‘X’ is een afkorting voor Explanatory variables (verklarende variabelen).

Zo bleven de AIC en BIC score goed presteren en bleven ook de ARIMA-termen van significante invloed. Tabel 5 geeft weer dat lag 5 en 6 van het woord “Funda” een significant effect op de woningprijsindex op tijdstip $t = 0$ binnen een betrouwbaarheidsinterval van 95 procent. Dit betekent dat de ontwikkeling van de zoekintensiteit van 5 en 6 maanden geleden een positief voorspellend effect heeft op de woningprijsontwikkeling op tijdstip $t = 0$. Een stijging van 1 in de zoekintensiteit op $t-5$ en $t-6$ heeft als gevolg een stijging van respectievelijk 0,066 en 0,065 van de woningprijsindex.

Het verband tussen het woord “Funda” en de woningprijzen 5 en 6 maanden later kan verklaard worden door de resultaten gepubliceerd door de Hongkong and Shanghai Banking Corporation (HSBC) waaruit blijkt dat het gehele proces binnen het Verenigd Koninkrijk, van begin zoektocht naar een woning tot de opname van het landelijk Kadaster, circa 6 maanden in beslag neemt (The Hongkong and Shanghai Banking Corporation (HSBC), 2012). Hetzelfde beeld wordt bevestigd door Redfin, een groot makelaarskantoor in de Verenigde Staten (Redfin, 2014). Aangezien Funda de grootste en belangrijkste zoekbron is voor consumenten en makelaars in de zoektocht naar een woning (Consultancy.nl, 2018) is dit een plausibele relatie.

Model 3 is een uitbreiding van het basismodel welke is aangevuld met de datareeks van het Consumentenvertrouwen. Door stapsgewijs de lags van het consumentenvertrouwen toe te voegen aan het basismodel is waargenomen dat de 8^e lag van het consumentenvertrouwen ten opzichte van andere lagtermijnen het beste presteert. Met een p-waarde van 0,043 is de variabele van significante invloed op de woningprijsindex binnen een betrouwbaarheidsinterval van 95 procent. De positieve coëfficiënt duidt op een positief verband. Wanneer het consumentenvertrouwen op tijdstip $t-8$ toeneemt neemt de woningprijsindex op tijdstip $t=0$ (8 maanden later) ook toe.

Dit resultaat kan ondersteund worden door bevindingen uit eerder onderzoek op het gebied van consumentenindices in relatie tot de vastgoedmarkt. Weber en Devaney (1996) tonen in hun onderzoek aan dat de Consumentenindex en de Housing sentiment index een voorspellende kracht hebben op de woningmarkt in de Verenigde Staten. De belangrijkste overeenkomst is dat in het onderzoek van Weber en Devaney de sterkste relatie gevonden is in de 9^e lag (3^e kwartaal) van het algemene consumentenvertrouwen, dit komt sterk overeen met de resultaten in dit onderzoek (tabel 5, model 3, 8^e lag van het consumentenvertrouwen). Uit een vergelijkbaar onderzoek op basis van data uit het Verenigd Koninkrijk blijkt tevens dat de lag tot en met het 3^e kwartaal (c.a. 9 maanden) van het consumentenindex een goede voorspeller is van de woningprijs (Garratt, 2000).

In het model 4 worden zowel de 5^e en 6^e lag van de Google zoekterm 'Funda', als de 8^e lag van het consumentenvertrouwen toegevoegd. In dit model vertonen lag 5 van het woord Funda en lag 8 van het consumenten vertrouwen minder significante resultaten. Dit duidt op onderliggende verbanden tussen het consumentenvertrouwen en de zoekintensiteit naar het woord Funda. De focus van dit onderzoek ligt op het voorspellen van datareeksen, waardoor de significantie van de variabelen van ondergeschikt belang is aan de voorspellende kracht van de modellen. Model 4 geeft gezien de positieve resultaten in model 2 en de gelijkblijvende coëfficiënten, voldoende vertrouwen om onderdeel uit te laten maken van de beoordeling van de voorspellende kracht.

Model diagnostiek

Een belangrijk onderdeel binnen time series, en ARIMA/ARIMAX modellen in het bijzonder, is het controleren van het model op haar robuustheid (Tse, 1997). Er zijn verschillende controles waarmee rekening gehouden dient te worden. Een gebruikelijke manier hiervoor is het controleren van de residuen, waarbij de focus ligt op het waarnemen van eventuele autocorrelatie (Brooks & Tsolacos, 2010). Binnen time series geven de residuen het verschil tussen de voorspelde en de daadwerkelijke waarde weer. Omdat de residuen geen verklarende kracht meer mogen bezitten, is het van belang dat zij gekenmerkt worden door white noise. White noise houdt in dat er is geen autocorrelatie waarneembaar is tussen de diverse datapunten en dat de datareeks normaal verdeeld is (Brooks & Tsolacos, 2010; Tse, 1997). Om zeker te zijn van de robuustheid van het model is ook in dit stadium ervoor gekozen om zowel een visuele als een statistische analyse uit te voeren. Per model is een Shapiro Wilkinson test, een cumulatieve periodogram, een histogram, een ACF plot en een Portmanteau test uitgevoerd en geanalyseerd. Een analyse van de residuen per model is gepresenteerd in Bijlage C.

Een eis van het ARIMA model is dat de residuen *normaal verdeeld* zijn. Om hier zeker van te zijn is ook een Shapiro wilkinson test (1965) uitgevoerd. Deze test heeft als nulhypothese dat de datareeks normaal verdeeld is (Shapiro & Wilk, 1965). Uit de resultaten van deze analyse blijkt dat de residuen allen normaal verdeeld zijn binnen een betrouwbaarheidsinterval van 95 procent, dit geeft voldoende vertrouwen om aan te nemen dat de testuitslagen niet significant zijn en de residuen van alle modellen dus normaal verdeeld zijn.

Vervolgens is er opnieuw een ACF-plot gemaakt van de residuen per model, met als doel te controleren op de eventuele aanwezigheid van autocorrelatie. Echter, zoals eerder genoemd, kan de werkelijke situatie afwijken van de visualisatie in beide plots. Om deze reden is er dan ook de Ljung-Box (1978) Portmanteau test uitgevoerd. Met de Portmanteau test kan

gecontroleerd worden op auto- en seriecorrelatie binnen de datareeks, in dit geval de residuen (Ljung & Box, 1978). De Portmanteau test is met name voor ARIMA-modellen een erg geschikte test om een uitspraak te kunnen doen over de aanwezigheid van white noise en autocorrelatie (Amonhaemanon et al., 2013; Brooks & Tsolacos, 2010). De Nul-hypothese luidt: De datareeks kent een white noise proces van niet-gecorrleerde random variabelen met een constant gemiddelde en variantie (Bartlett, 1978). Uit de Portmanteau test is gebleken dat alle vier de modellen voldoen aan de white noise-eis binnen een betrouwbaarheidsinterval van 95 procent.

Conform de theorie van Bartlett (1995) gaat een Portmanteau test veelal gepaard met een cumulatieve periodogram, welke grafisch de afwijking van een white noise proces weergeeft. In de periodogrammen in Bijlage C wordt met een diagonale lijn het white noise proces weergegeven. Het grijze vlak geeft de 95 procent betrouwbaarheidsinterval weer. Indien waardes buiten dit gebied vallen betekent dit dat de datareeks significant afwijkt van een white noise proces. Ook hier wordt duidelijk dat alle modellen voldoen aan de white noise proces eis.

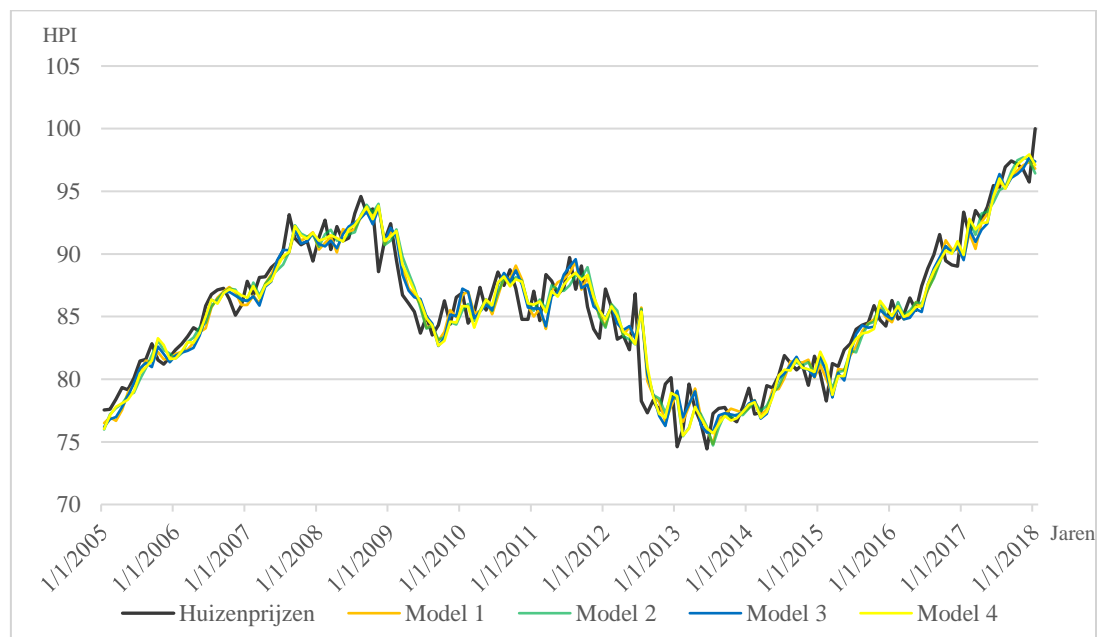
Door bovengenoemde testen uit te voeren op de residuen kan met voldoende zekerheid aangenomen worden dat de residuen van de vier modellen een white noise proces volgen waarbij de reeksen normaal verdeeld zijn en geen autocorrelatie kennen. Hierdoor is er voldoende vertrouwen dat de modellen adequaat, robuust en geschikt zijn voor de volgende stap in het proces van het ARIMA-model; het voorspellen.

Forecasting

In deze paragraaf wordt de voorspellende kracht van de vier modellen getoetst. Op basis van een In-sample voorspelling wordt de afwijking van de voorspelling ten opzichte van de daadwerkelijke waarde berekend en geanalyseerd. Voor ieder van de modellen is handmatig de voorspellende kracht van het model berekend. In figuur 4 zijn voor de vier modellen de voorspelde datareeksen ten opzichte van de daadwerkelijke woningprijsindex gevisualiseerd. Visueel zijn er geen grote verschillen waarneembaar tussen de vier modellen. Om een uitspraak te kunnen doen over de onderlinge kwaliteitsverschillen van de ontwikkelde modellen worden diverse handmatige berekeningen uitgevoerd die de voorspellende kracht toetsen.

In tabel 7 worden per model de uitkomsten van de MSE berekeningen getoond. Een lagere waarde betekent dat het verschil tussen de voorspelde en de daadwerkelijke waarde kleiner is, dit duidt dus op een goed/beter model. Zoals in de tabel valt af te lezen bedraagt de MSE van

het basis model (1) 4,97. Een toevoeging van de 5^e en 6^e lag van de zoekterm Funda aan het basis model resulteert in een verbeterde MSE van 4,9. De MSE van model 1 ten opzichte van model 2 daalt met 1,43 procent. Op basis hiervan is de bevinding gerechtvaardigd dat de 5^e en 6^e lag van de zoekintensiteit naar het woord Funda niet enkel een significante voorspeller zijn van de woningprijsindex zoals eerder waargenomen, maar ook van toegevoegde waarde zijn in de voorspelling van de woningprijsindex ten opzichte van het basis model.



Figuur 4 Grafiek In-sample voorspellingen vier modellen ten opzichte van daadwerkelijke huizenprijsindex (HPI)

Het resultaat dat model 2, het ARIMAX model, beter presteert dan model 1, het ARIMA model, komt op hoofdlijnen overeen met de constatering uit een vergelijkbaar onderzoek. Peter en Silvia (2012) hebben onderzoek gedaan naar de verschillen in voorspellende kracht van ARIMA en ARIMAX modellen. In hun onderzoek waarnemen zij dat ARIMAX modellen nauwkeuriger diverse economische parameters kunnen voorspellen dan ARIMA modellen (Peter & Silvia, 2012).

Model 3 vertoont een lagere MSE dan het basismodel en model 2, respectievelijk 2,79 ten opzichte van 4,97 en 4,90. Dit betekent dat binnen dit onderzoek het ARIMAX model waaraan de 8^{ste} lag van het consumentenvertrouwen is toegevoegd een meer realistische voorspelling van de werkelijkheid biedt dan het basis model 1 en model 2 waaraan enkel de Google zoekterm Funda is toegevoegd.

Het meest opvallende resultaat wordt geboden door het 4^e model. In dit model zijn zowel de Google zoekterm Funda (5^e en 6^e lag) als ook de 8^e lag van het consumentenvertrouwen

toegevoegd. Door middel van dit model is getest of dat naast het feit dat de term Funda een voorspellende kracht heeft, het woord Funda ook van toegevoegde en onderscheidende waarde is ten opzichte van de sentimentparameter consumentenvertrouwen. Uit de analyse is gebleken dat de voorspellende kracht van model 4 met maar liefst 10,15 procent toeneemt ten opzichte van model 3. Dit, terwijl er geen veranderingen optreden in de karakteristieken en significantieniveaus van de ARMA-termen. Google Trends bezit dus niet alleen een voorspellende kracht, maar is tevens van (unieke) toegevoegde waarde op de klassieke parameter consumentenvertrouwen.

Tabel 6. Uitkomsten Mean Squared Error

	(1) Basis	(2) Forecast Funda	(3) Forecast Cons. vertr.	(4) Forecast Cons. vertr. en Funda
Mean Squared Error (MSE)	4,97	4,90	2,79	2,53

5. Conclusie en discussie

Het gebruik van Google Trends data is binnen een breed scala aan vak- en onderzoeksgebieden een waardevolle bron gebleken voor het ontwikkelen van voorspellende modellen. Tot op heden zijn er geen onderzoeken verricht naar de toegevoegde waarde van Google Trends in de voorspelling van de Nederlandse woningprijzen met behulp van een ARIMA(X) model. In volgorde van de in paragraaf 2,5 geformuleerde hypothesen zullen onderstaand de bevindingen van dit onderzoek weergegeven worden.

Hypothese 1: Google Trends data is van toegevoegde waarde bij de voorspelling van de woningprijzen in Nederland.

In dit onderzoek is een basismodel (ARIMA) ontwikkeld welke de woningprijzen kan voorspellen met een MSE van 4,97 (model 1). Door een 13-tal Google Trends termen en 11 lags per term toe te voegen aan dit basismodel is gezocht naar de optimale indicator voor het sentiment in de woningmarkt. Uit deze analyse is gebleken dat de zoekfrequentie van het woord “Funda” een significante positieve relatie vertoont met de woningprijzen in Nederland 5 en 6 maanden later (model 2). Aangezien Funda de grootste en belangrijkste zoekbron is voor consumenten en makelaars is het plausibel dat er, zoals in dit onderzoek waargenomen, een positieve relatie bestaat tussen de zoekfrequentie naar het woord Funda en de woningprijzen. Dit maakt de term Funda een geschikte indicator voor het sentiment in de woningmarkt. De voorspellende kracht van het ARIMAX-model (model 2, inclusief Funda zoekterm), is beter dan die van het basismodel 1 (MSE van 4,97 versus 4,9). Uit dit onderzoek blijkt dus dat Google Trends-data van toegevoegde waarde is voor het ontwikkelen van een model dat met meer nauwkeurigheid betere voorspellingen kan doen van de ontwikkeling van de woningprijzen in Nederland. Op basis van deze bevindingen is *Hypothese 1* aangenomen.

Hypothese 2: Het consumentenvertrouwen is van toegevoegde waarde in de voorspelling van de woningprijzen.

Uit literatuuronderzoek is gebleken dat het consumentenvertrouwen een goede indicator is van het sentiment binnen de vastgoedmarkt. Om de relatieve kwaliteit van de voorspellende kracht van Google Trends te kunnen toetsen is onderzocht hoe de voorspellende kwaliteit van Google Trends zich verhoudt tot die van het consumentenvertrouwen. Model 3 toont binnen een betrouwbaarheidsinterval van 95 procent aan dat de 8^e lag van het consumentenvertrouwen van toegevoegde waarde is bij het voorspellen van de woningprijs op $t=0$. De voorspellende kracht van dit model is met een MSE van 2,79 beter dan zowel het basismodel 1 als model 2. Data met betrekking tot het consumentenvertrouwen is dus van toegevoegde waarde voor de nauwkeurigheid en de kracht van de voorspelling van de ontwikkeling van de woningprijzen binnen Nederland. Op basis van deze bevindingen is *Hypothese 2* aangenomen.

Hypothese 3: Met behulp van Google Trends-zoektermen kan een meer nauwkeurige voorspelling van de woningprijzen worden gedaan dan door middel van het opnemen van het consumentenvertrouwen.

Model 2 levert met een MSE van 4,90 een betere voorspellende kracht dan het basismodel 1 (MSE 4,97). Model 3, waarbij aan het basismodel de consumentenvertrouwensindex is toegevoegd, presteert met een MSE van 2,79 echter nog beter dan voorgenoemde modellen. Hieruit kan opgemaakt worden dat het model waaraan Google Trends data is toegevoegd niet in staat is de woningprijzen nauwkeuriger te benaderen dan het consumentenvertrouwen. *Hypothese 3* kan dus op basis van de resultaten in dit onderzoek niet worden aangenomen. Echter kan in aanvulling hierop een interessante waarneming gedaan uit een analyse van de voorspellende kracht van model 4, waarin zowel lag 5 en 6 van de term “Funda” als lag 8 van het consumentenvertrouwen zijn verwerkt. Dit model voorspelt, met een MSE van 2,53, de woningprijs het meest nauwkeurig van de vier modellen. Hiermee is aangetoond dat Google Trends data van unieke toegevoegde waarde is in de voorspelling van de woningprijs ten opzichte van de ‘klassieke’ fundamentele indicator consumentenvertrouwen.

Met dit onderzoek en met bovengenoemde conclusies wordt een bijdrage geleverd aan de literatuur op het gebied van voorspellende modellen. De resultaten uit dit onderzoek wijzen op een toegevoegde waarde van modellen waarin de relatie gelegd wordt tussen technische analyse (ARIMA/model 1) en fundamentele analyse (ARIMAX/model 3+4). Uit dit onderzoek blijkt namelijk dat de ontwikkeling van woningprijzen meer nauwkeurig benaderd kan worden op basis van zowel data uit voorafgaande perioden, als fundamentele klassieke variabelen zoals het consumentenvertrouwen en Google Trends in het verlengde daarvan. Dit is in strijd met het gedachtegoed van de Efficiënte Markt Hypothese en duidt dus op imperfecties en inefficiëntie van de woningmarkt. Hiermee wordt bijgedragen aan de discussie met betrekking tot de efficiënte werking van de vastgoed- en woningmarkt. Het gebruik van Google Trends data heeft de afgelopen decennia aan populariteit gewonnen binnen de wetenschappelijke literatuur. De resultaten uit dit onderzoek valideren door het aantonen van de toegevoegde waarde van het gebruik van data het terechte gebruik en de groei in populariteit daarvan. Dit betreft slechts één van de mogelijke toepassingsgebieden.

Desondanks moet met een paar aspecten rekening worden gehouden. Allereerst is het van belang om te realiseren dat Google Trends-data geen absolute data biedt. Absolute data is tot op heden nog niet beschikbaar, maar de beschikking daarover zou de kwaliteit van dit onderzoek ten goede komen. Een ander aandachtspunt is dat de zoekintensiteit op Google niet altijd enkel de daadwerkelijke interesse van mensen om te (ver)kopen weer zal geven. Om het woord “Funda” als voorbeeld te nemen: niet alle bezoekers zullen de website van Funda enkel

bezoeken om hun woning te koop aan te bieden of te zoeken naar een nieuwe geschikte woning. Wellicht maken zij ook gebruik van Funda om simpelweg een kijkje te nemen in het te koop staande huis van de burens of een exclusief grachtenpand in Amsterdam.

Een derde aspect is de relatief beperkte beschikbaarheid van de data. Hoewel data vanaf januari 2004 geschikt is om een analyse te maken van de korttermijn voorspelling, is een gedetailleerde analyse op de lange termijn uitgesloten. Echter, zelfs wanneer er meer data beschikbaar was, kent de Google Trends-data de beperking van het toegenomen internet gebruik de afgelopen jaren. Dit maakt informatie van voor 2004 mogelijk minder relevant.

Door de brede toepasbaarheid van Google Trends zijn er diverse onderzoeksrichtingen die nader verkend kunnen worden. De conclusies van dit onderzoek zijn met name verkennend van aard en relevant voor een meer accurate voorspelling van de woningprijzen. In eerste instantie met name relevant voor beleidmakers, ontwikkelaars en beleggers. Echter, gedreven door de toenemende datatransparantie en databeschikbaarheid en de steeds verder gaande digitalisering in de vastgoedsector zal data-analyse steeds breder en dieper worden toegepast. En zullen de relevantie van dit onderzoek en de daaruit voortgevloeide conclusies steeds meer toenemen. Wanneer datatransparantie, databeschikbaarheid, het gebruik van online platformen, de kwaliteit en kwantiteit van data in de toekomst steeds verder toenemen zou dit kunnen leiden tot een, conform de EMH, meer efficiënte woningmarkt. Het is dan ook zinvol om periodiek een vergelijkbaar onderzoek te verrichten om op die manier de stand en de voortgang van de ontwikkelingen op dit gebied te volgen en de voorspellende kracht van modellen steeds verder te perfectioneren.

Verder onderzoek kan zich ook richten op een analyse op een lager aggregatieniveau of op een verschillenanalyse tussen diverse schaalniveaus (landelijk/regionaal/stedelijk). Ook zou met de conclusies van dit onderzoek de ontwikkeling van een unieke woningmarktindicator kunnen worden onderzocht. Een indicator die op basis van real time databronnen een nauwkeurige korte termijn voorspelling van de woningmarkt biedt. Aanvullend hierop zouden er ter verbetering van de uitkomsten van dit onderzoek simulaties kunnen worden uitgevoerd. Bijvoorbeeld een Monte-Carlo simulatie, waarbij alle mogelijke modellen en Google Trends zoektermen worden geconstrueerd, geanalyseerd en gecombineerd (composite indicator) om vervolgens het beste model voor de voorspelling van woningprijzen te kunnen ontwikkelen. Dit onderzoek betreft een eerste verkenning, waardoor de hierboven beschreven onderzoeksrichtingen de grenzen van dit onderzoek overschrijden.

Bibliografie

- Ajzen, I. (1991). The theory of planned behavior. *Organizational Behavior and Human Decision Processes*, 50(2), 179-211.
- AL-Nahdi, T., Habib, S., & Albdour, A. (2015). Factors Influencing the Intention to Purchase Real Estate in Saudi Arabia: Moderating Effect of Demographic Citizenship. *International Journal of Business and Management*, 10(4).
- Amonhaemanon, D., De Ceuster, M., Annaert, J., & Le Long, H. (2013). The inflation-hedging ability of real estate evidence in Thailand. *Procedia Economics and Finance*, 5, 40-49.
- Askitas, N., & Zimmermann, K. (2009). Google econometrics and unemployment forecasting. *Applied Economics Quarterly*, 55(2), 107-120.
- Bartlett, M. (1978). *An introduction to Stochastic Processes with Special Reference to Methods and Applications*. Cambridge University Press.
- Beracha, E., & Wintoki, M. (2013). Forecasting Residential Real Estate Price Changes from Online Search Activity. *Journal of Real Estate Research*, 35(3).
- Borger, E. (2018, januari). *Marktaandeelen zoekmachines Q1 2018*. Retrieved from Pure-im: <https://www.pure-im.nl/blog/marktaandeelen-zoekmachines-q1-2018/>
- Brooks, C., & Tsolacos, S. (2010). *Real Estate Modelling and Forecasting*. Cambridge: Cambridge University Press.
- Case, K., & Shiller, R. (1989). The Efficiency of the Market for Single-Family Homes. *American Economic Review*, 79(1), 125-137.
- CBS. (2018, juni). *Consumentenvertrouwen*. Retrieved from <https://www.cbs.nl/nl-nl/onze-diensten/in-de-klas/conjunctuurbekering/te-voorspellen-indicatoren/consumentenvertrouwen>
- Chmyznikov, G., & Galvanauskas, L. (2013). *Forecasting economic activity in the Baltics: Let us Google it*. Riga: SSE Riga Students Research Papers.
- Choi, H., & Varian, H. (2012). Predicting the Present with Google Trends. *The Economic Record*, 88(Special Issue), 2-9.
- Chun, H. (2017). A study on the impact of changes in consumer sentiment on the housing market in Korea. *International Journal of Urban Sciences*, 21(2), 129-146.
- Consultancy.nl. (2018, juni 6). *De 80 grootste websites en meest gebruikte apps van Nederland*. Retrieved from <https://www.consultancy.nl/nieuws/18054/de-80-grootste-websites-en-meest-gebruikte-apps-van-nederland>

- Das, P. (2013). *Online Information Search, Market Fundamentals and Apartment Real Estate*. Atlanta: Georgia State University - Department of Real Estate.
- De Vries, P. (2010). *Measuring and explaining*. Delft: Delft University.
- Dickey, D., & Fuller, W. (1981). Likelihood ratio statistics for autoregressive time series with a unit root. *Econometrica*, 12(8), 641-642.
- Dietzel, M. A. (2016). Sentiment-based predictions of housing market turning points with Google trends. *International Journal of Housing Markets and Analysis*, 1, 108-136.
- Dietzel, M. A., Braun, A., & Schäfers, W. (2014). Sentiment-based commercial real estate forecasting with Google search volume data. *Journal of Property Investment and Finance*, 32(6), 540-569.
- Égert, B., & Mihaljek, D. (2007). Determinants of house prices in central and eastern Europe . *BIS Working Paper*, No. 236.
- Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *Journal of Finance*, 25, 383-417.
- Figurska, M., & Wisniewski, R. (2016). Fundamental Analysis - Possibilities of Application on the Real Estate Market. *Real estate Management and Valuation*, 24(4), 35-46.
- Garratt, D. (2000). Consumer confidence and UK house price inflation. *Housing Finance*, vol. 46.
- Gawlik, E., Kabaria, H., & Kaur, S. (2011). *Predicting tourism trends with Google Insights*.
- Ginsberg, J., Mohebbi, M. H., Patel, S. R., Brammer, L., Smolinski, M. S., & Brilliant, L. (2009). Detecting influenza epidemics using search engine query data. *Nature*, 457(7232), 1012-1014.
- Glaeser, E. L. (2008). Housing Prices in the Three Americas. *New York Times*.
- Glaeser, E. L., & Gyourko, J. (2006). Housing Dynamics. *NBER Working Paper*, no. 12787.
- Jin, C., Soydemir, G., & Tidwell, A. (2014). The U.S. Housing Market and the Pricing of Risk: Fundamental Analysis and Market Sentiment. *Journal of Real Estate Research*, 36(2).
- Jun, S.-P., Yoo, H. S., & Choi, S. (2017). Ten years of research change using Google Trends: From the perspective of big data utilizations and applications. *Technological Forecasting and Social Change*.
- Kristoufek, L. (2013). Bitcoin meets Google Trends and Wikipedia: Quantifying the relationship between phenomena of the internet era. *Scientific reports*, pp. 3, 3415.
- Levenbach, H. (2017). *Change & Chance Embraced: Achieving Agility with Demand Forecasting in the Supply Chain* . Delphus Publishing .

- Lind, J. (2015). *Research question: Is it possible to predict real estate prices*. Amsterdam: Vrije Univeristeit Amsterdam.
- Ljung, G., & Box, G. (1978). On a measure of lack of fit in time series models. *Biometrika*, 65(2), 297-303.
- Maier, G., & Herath, S. (2009). *Real Estate Market Efficiency. A Survey of Literature*. Wenen: Institut für Regional-und Umweltwirtschaft, WU Vienna University of Economics and Business.
- Makridakis, S., & Hibon, M. (2011). ARIMA Models and the Box–Jenkins Methodology. In *Applied Econometrics (Second ed.)* (pp. 265-286). Palgrave MacMillan.
- Marcato, G., & Nanda, A. (2014). Information content and forecasting ability of sentiment indicators: case of real estate market. *Journal of Real Estate Research*, 1(1).
- Mills, A., & Skitmore, M. (2003). The accuracy of housing forecasting in Australia. *Engeneering Construction and Architectural Management*, 10(4), 245-253.
- NetMarketshare. (2018, mei 28). *Search Engine Market Share*. Retrieved from Net Marketshare: <https://netmarketshare.com/search-engine-market-share.aspx>
- Önder, I. (2017). Forecasting tourism demand with Google trends: Accuracy comparison of countries versus cities. *International Journal of Tourism Research*, 19, 648-660.
- Peter, Ď., & Silvia, P. (2012). ARIMA vs. ARIMAX – which approach is better to analyze. *Mathematical methods in Economics: proceedings of 30th international conference*, (pp. 136-140). Karviná, Czech Republic.
- Petrevska, B. (2017). Predicting tourism demand by A.R.I.M.A. models. *Economic Research-Ekonomska Istraživanja*, 30(1), 939-950.
- Phillips, P., & Perron, P. (1988). Testing for a unit root in time series regression. *Biometrika*, 75, 335-346.
- Redfin. (2014, maart 21). *Home Buying and Selling Calender*. Retrieved from <https://www.redfin.com/blog/2014/03/real-estate-survival-guide.html>
- Shapiro, S., & Wilk, M. (1965). An analysis of variance test for normality (complete samples). *Biometrika*, 52 (3-4), 591-611.
- Shiller, R. J. (2008). Historic turning points in real estate. *Eastern Economic Journal*, 34(1), 1-13.
- The Hongkong and Shanghai Banking Corporation (HSBC). (2012). *UK Housing Market Chart Book*. Retrieved from HSBC: <http://www.raglaninternational.com/housing160412.pdf>

- Tse, R. Y. (1997). An application of the ARIMA model to real-estate prices in Hong Kong. *Journal of Property Finance*, 8(2), 152-163.
- Van Dijk, D., & Francke, M. (2015). Internet search behavior, liquidity and prices in the housing market. *DNB Working Paper*, No. 481.
- Van Veldhuizen, S., Vogt, B., & Voogt, B. (2016). *Internet searches and transactions on the Dutch housing market*. CPB Netherlands Bureau for Economic Policy Analysis.
- Verbruggen, R., & Heijs, W. (2017, maart). Duurzaam zorgvastgoed: de Theory of Planned Behaviour als verklarende kader voor beslissingen over duurzaamheidsmaatregelen. *Real Estate Research Quarterly*, pp. 29-37.
- Vosen, S., & Schmidt, T. (2011). Forecasting private consumption: survey-based indicators vs Google Trends. *Journal of Forecasting*, 30, 565-578.
- Vu, J. C., & Turner, L. W. (2006). Regional Data Forecasting Accuracy: The Case of Thailand. *Journal of Travel Research*, 45(2), 186 - 193.
- Wang, Z., & Hui, E. C. (2016). Fundamentals and Market Sentiment in Housing market. *Housing, Theory and Society*, 34(1), 57-78,.
- Weber, W., & Devaney, M. (1996). Can consumer sentiment surveys forecast housing starts. *Appraisal Journal*, 4(1), 343-350.
- Wu, L., & Brynjolfsson, E. (2009). *How Google Searches Foreshadow Housing Prices and Sales*. Technical report, MIT.
- Wu, L., & Brynjolfsson, E. (2015). The Future of Prediction: How Google Searches Foreshadow Housing Prices and Sales. *Economic analysis of the digital economy*, 89-118.
- Yang, X., Pan, B., Evans, J. A., & Lv, B. (2014). Forecasting Chinese tourist volume with search engine data. *Tourism Management Exclusively*.

Bijlagen

Bijlage A: Analyse diverse onderzoeken



Auteur	Wu and Brynjolffson (2009)	Jalan E. Panchapagesan V., Venkataraman M. (2017)	Ristov (2016)	Beracha, E. and Wintoki, M.B. (2013)	Dietzel, M.A.; Broun, N.; Schaefer, W. (2014)	Askitas, N. (2015)	Lind, J. (2015)	Van Veldhuizen, Vogt en Voogt (2016)	Das, P. (2013)
Methode	AR model	Regressie analyse	ARIMA en VAR	Regressie analyse	VAR model	AR model	ARIMA	Regressie analyse	VAR model
Afhankelijke variabele	Woningprijzen en transacties	Woningprijzen en huren van 4 steden (gecombineerd)	Woningprijzen en transacties stad	Woningprijzen	Commerciële vastgoedprijzen (huur en koop)	Housingprices (S&P/Case-Shiller Home Price)	Woningprijzen	Woningtransacties	Leegstandspercentages, huurprijzen, vastgoed rendementen
Type zoektermen/index:	Losse woorden en index van meerdere woorden	Diverse eigen categorieën op basis van Combinaties van diverse losse woorden	Enkel woord	Meerdere woorden	Analyse per Google subcategorie en combinaties van woorden	Buse Index: “buy-sell”-ratio berekend, gebaseerd op zoekfrequentie naar de termen ‘kopen’ en ‘verkopen’	Meerdere losse woorden	Enkel woord	Categorie
Zoekterm/categorie	Termen in de categorie: “vastgoed”	Object (property), Verkoop, Woningverkoop + appartement verkoop, huur, vastgoed	“Huis Te Koop”	Vastgoed, huur	Subcategorie: Commercieel en investeringsvastgoed, Huurwoningen	Index o.b.v. ‘kopen’ en ‘verkopen’	Hemnet (Grootste Zweedse online makelaar), Rente, Hypotheek, Appartement kopen, Huis kopen, Inflatie	“Hypotheek”	Categorie: “appartementen en onroerend goed”
	Termen in de categorie: “vastgoedmakelaar”				Combinatie van zoektermen omtrent: Commercieel vastgoed				
					Zoektermen gerelateerd aan: kantoorobject, winkelobject, online makelaar				

Bijlage B: Uitkomsten AIC en BIC

ARIMA Model	AR	MA	AIC	BIC
(1,1,1)	no	*	664.1849	676.6807
(1,1,2)	***	***	664.1825	679.8023
(1,1,5)	no	1/5	665.3651	690.3568
(1,1,6)	no	3/6	665.545	693.6607
(1,1,7)	no	1/7	659.1478	690.3875
(1,1,8)	***	4/8	653.4868	687.8504
(1,1,9)	no	2/9	652.3761	689.8637
(1,1,10)	no	5/10	656.9118	697.5233
(2,1,1)	1/2	no	664.0336	679.6534
(2,1,2)	***	***	657.2388	675.9826
(2,1,5)	1/2	3/5	658.2835	686.3992
(2,1,6)	***	4/6	657.8903	689.13
(2,1,7)	1/2	2/7	657.6418	692.0054
(2,1,8)	1/2	4/8	653.2405	690.7281
(2,1,9)	1/2	3/9	653.212	693.8236
(2,1,10)	1/2	4/10	654.6441	698.3796
(3,1,1)	***	***	665.3047	684.0484
(3,1,2)	1/3	1/2	663.9842	685.852
(3,1,5)	1/3	2/5	660.1719	691.4115
(3,1,6)	1/3	1/6	662.1235	696.4871
(3,1,7)	no	2/7	659.3976	696.8852
(3,1,8)	1/3	1/8	660.1834	700.795
(3,1,9)	1/3	2/9	654.6028	698.3383
(3,1,10)	1/3	2/10	656.6028	703.4623
(5,1,1)	1/5	***	662.7487	687.7404
(5,1,2)	2/5	***	659.859	687.9747
(5,1,5)	***	***	654.5338	692.0214
(5,1,6)	***	4/6	653.7867	691.2743
(5,1,7)	***	no	658.2139	701.9494
(5,1,8)	4/5	no	660.195	707.0545
(5,1,9)	no	no	659.4567	709.4401
(5,1,10)	1/5	5/10	656.1625	706.1459
(6,1,1)	2/6	no	657.7825	685.8982
(6,1,2)	2/6	no	656.903	688.1426
(6,1,5)	5/6	4/6	653.8743	691.3619
(6,1,6)	6/6	no	651.9038	692.5154
(6,1,7)	1/6	no	658.9962	705.8557
(6,1,8)	1/6	no	659.7455	706.605
(6,1,9)	1/6	2/9	660.5852	713.6926
(6,1,10)	no	no	662.6374	718.8688
(7,1,1)	1/7	no	659.1165	690.3562
(7,1,2)	3/7	1/2	658.1076	692.4712
(7,1,5)	5/7	no	658.247	701.9825
(7,1,6)	2/7	1/6	659.0617	705.9212
(7,1,7)	3/7	no	655.3993	702.2588
(7,1,8)	3/7	no	659.2353	709.2187
(7,1,9)	1/7	no	661.5058	717.7371
(7,1,10)	no	2/10	657.7938	710.9012
(23,1,1)	no	no	671.1156	752.3387
(23,1,2)	no	no	673.0941	757.4412
(23,1,5)	no	no	668.4707	759.0657
(23,1,6)	no	no	663.9145	754.5095
(23,1,7)	to many iterations		to many iterations	
(23,1,8)	to many iterations		to many iterations	
(23,1,9)	to many iterations		to many iterations	
(23,1,10)	to many iterations		to many iterations	
(24,1,1)	5/24	***	672.6998	757.0469
(24,1,2)	1/24	1/2	674.6844	762.1554
(24,1,5)	to many iterations		to many iterations	
(24,1,6)	to many iterations		to many iterations	
(24,1,7)	to many iterations		to many iterations	
(24,1,8)	to many iterations		to many iterations	
(24,1,9)	to many iterations		to many iterations	
(24,1,10)	to many iterations		to many iterations	
(25,1,1)	1/25	no	674.6844	762.1554
(25,1,2)	2/25	no	667.5476	767.5145
(25,1,5)	to many iterations		to many iterations	
(25,1,6)	5/25	no	667.5476	767.5145
(25,1,7)	5/25	no	to many iterations	
(25,1,8)	to many iterations		to many iterations	
(25,1,9)	to many iterations		to many iterations	
(25,1,10)	to many iterations		to many iterations	

Bijlage C: Controle Residuen

Check model 1:




Portmanteau test for white noise

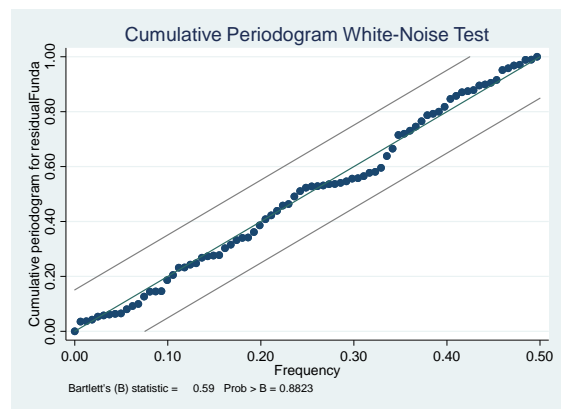

Portmanteau (Q) statistic = **53.8395**
 Prob > chi2(40) = **0.0707**

Shapiro-Wilk W test for normal data

Variable	Obs	W	V	z	Prob>z
residualBa~s	168	0.99526	0.608	-1.135	0.87178



Check model 2:




Portmanteau test for white noise


Portmanteau (Q) statistic = **41.3438**
 Prob > chi2(40) = **0.4118**

Shapiro-Wilk W test for normal data

Variable	Obs	W	V	z	Prob>z
residualFu~a	161	0.99593	0.503	-1.563	0.94102



Check model 3




Portmanteau test for white noise

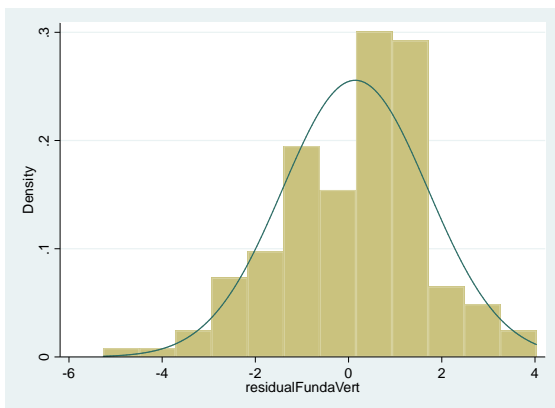
Portmanteau (Q) statistic = **52.9557**
 Prob > chi2(40) = **0.0824**

Shapiro-Wilk W test for normal data

Variable	Obs	W	V	z	Prob>z
residualVert	159	0.98976	1.253	0.513	0.30408



Check model 4



Portmanteau test for white noise

Portmanteau (Q) statistic = **44.7744**
 Prob > chi2(40) = **0.2783**

Shapiro-Wilk W test for normal data

Variable	Obs	W	V	z	Prob>z
residualFu-t	159	0.98344	2.026	1.605	0.05421

