

Credit Scoring; Signaling Risk of Late Payment

Het signaleren van risico op vertraagde betalingen bij F-gas gecertificeerde installateurs in Nederland



Door: O.A. Onemu
Studentnr: 351245
Versie en datum: V5.3, juni 2013

Inhoudsopgave

1	<i>Inleiding</i>	3
1.1	Introductie & motivatie	3
1.1.1	Centrale onderzoeksvraag	4
1.1.2	Onderzoeksdoelstelling	4
1.1.3	Gedachte achter de in scope genomen onderzoeksvariabelen	4
1.1.4	Leeswijzer	5
1.2	Relevantie	6
1.2.1	Praktische relevantie	6
1.2.2	Theoretische relevantie	6
1.3	Methoden van aanpak & Theoretisch referentiekader	7
1.3.1	Creditscoring, een korte introductie	7
1.3.2	Enkele statistische methoden verder belicht.....	9
1.3.3	Data verzameling & afbakening.....	10
1.3.4	Methodologische aanpak en onderzoeksplanning	11
2	<i>Onderzoeksonderwerp</i>	14
2.1	Conceptueel model	14
2.2	Doelstelling	15
2.3	Hypothesen	15
2.4	Begripsbepaling en “empirische vertaling”	15
2.4.1	Onderzoeksinstrumenten	17
3	<i>Empirische bevindingen, analyse en deelconclusies</i>	18
3.1	Fase 1, descriptieve- & (logistische) regressie analyse	18
3.1.1	Deelconclusie fase 1, descriptieve- & (logistische) regressie analyse	25
3.2	Fase 2, CHAID analyse	26
3.2.1	Deelconclusie fase 2, (exhaustive) CHAID analyse op basis van een 95% betrouwbaarheid.....	28
3.3	Fase 3, C(A)RT analyse	29
3.3.1	Deelconclusie fase 3, C(A)RT analyse op basis van een 95% betrouwbaarheid.....	34
4	<i>Conclusies & aanbevelingen</i>	35
4.1	Samenvatting	35
4.1.1	descriptieve- & (logistische) regressie analyse	35
4.1.2	(exhaustive) CHAID analyse op basis van een 95% betrouwbaarheid	35
4.1.3	C(A)RT analyse op basis van een 95% betrouwbaarheid	36
4.2	Hypothesen, conclusies & aanbevelingen	37
5	<i>Methodologische reflectie</i>	40
6	<i>Bibliografie</i>	43

1 Inleiding

1.1 Introductie & motivatie

Actief in een financiële omgeving van een Nederlandse verkooporganisatie, welke producten verkoopt aan Nederlandse F-gas gecertificeerde installateurs, zie ik met regelmaat de vraag voorbij komen om klanten te analyseren, beoordelen, voordat er goederen en/of diensten verkocht worden. Deze analyse gebeurt regelmatig op basis van de ervaring en praktijkkennis welke aanwezig is binnen de financiële afdeling van de organisatie. Er zijn tools beschikbaar, waardoor adviezen eenvoudig kunnen worden overgenomen. Toch word er vaak gekozen om af te wijken van het advies dat bijvoorbeeld kan zijn afgegeven door gespecialiseerde, internationaal actieve, organisaties als onder meer een Euler Hermes en/of een Dun & Bradstreet. Met regelmaat is het zo dat cijfers welke voortkomen uit een jaarrekening leiden tot een kredietlijn en de hoogte hiervan volgens de inschatting, conclusie, van de eigen onderneming. Deze conclusie wijkt met regelmaat af van de beoordeling van kredietbeoordelaars en het idee leeft dat de meer generieke adviezen mogelijk leiden tot foute, te algemene, beslissingen. Later in dit onderzoek zal hier dieper op worden ingegaan, maar binnen deze context introduceren we hier alvast twee risico's verbonden aan het onjuist inschatten van risico. Fout I: de afnemer (het bedrijf) wordt beoordeeld als slechte betaler, maar is dit niet. Gevolg hiervan kan zijn dat er opportuniteitsverliezen optreden. Fout II: de afnemer wordt beoordeeld als goede betaler en blijkt dit niet te zijn, met alle risico's van dien. Deze foutsoorten zijn ook weergegeven in onderstaande tabel 1.

	Classificatie
Foutsoorten	Wanbetaler Goede betaler
Goede betaler	Foutsoort I
Wanbetaler	Foutsoort II

Tabel 1 Foutsoorten

Bovenstaande deed mij een en ander afvragen, ook aangezien ik vernam dat meerdere leveranciers in de sector een gelijkaardige manier van werken hanteerde. Welke financiële parameter kan nu als belangrijkste factor worden beschouwd voor het afwijken van de adviezen van gespecialiseerde bedrijven, en vormt reden om te vertrouwen op de eigen inschatting van het risico? Het viel me op dat bedrijven regelmatig terugvallen op eigen procedures en regels (scorecards) om tot een beslissing te komen voor verstrekking van leverancierskrediet. Door te kijken naar de jaarrekening(en) van bedrijven en specifiek te letten op bepaalde (ken)getallen is men instaat het risico in te schatten. In dit onderzoek zouden we graag isoleren wat nu de voornaamste factor, lees driver, is voor het inschatten van risico op vertraagde betaling en deze "predictor, ofwel modificerende factor" willen voorstellen als structureel te hanteren indicator(en) van risico, de main driver(s)? Met andere woorden, zichtbaar maken wat de uiteindelijk sterkste invloed van een (combinatie van) variabele uit de gepubliceerde cijfers (jaarrekening) is op de te verwachte betalingservaringen, teneinde een betrouwbare risicobeoordeling te doen zonder bijkomende kosten vanuit kredietbeoordelaars.

Gezien de huidige veranderingen in de economische situatie op het gebied van kredietwaardigheid maakt dit het onderwerp een interessant onderwerp om verder te onderzoeken.

1.1.1 Centrale onderzoeksvraag

Gedurende dit onderzoek is er gezocht naar een antwoord op de vraag:

“Welke variabele heeft, of groep van variabelen hebben de sterkste, significante invloed op kredietrisico onder afnemers, waarbij het risico wordt uitgedrukt in de snelheid van betaling?”

1.1.2 Onderzoekdoelstelling

Er is in dit onderzoek gezocht naar een of meerdere variabele welke kan worden gebruikt als sterke predictor, of modificerende factor, waarmee mogelijk risico op vertraagde betaling kan worden verklaard en beperkt. Deze indicator kan vervolgens bijvoorbeeld worden ingezet als eerste indice voor de bepaling van eventueel aanwezig risico op betalingsvertragingen bij een afnemer. Zo ook bij de nuancering van meer generiek bepaalde kredietbeoordeling, lees ten behoeve van verfijning of vervanging van kredietbeoordelingen door derden en verhoogde aandacht voor opvolging van specifieke risicogroepen/-klanten. Op deze wijze kan de kredietwaardigheid mogelijk met een grotere mate van zekerheid worden bepaald en kunnen financiële verliezen worden beperkt.

1.1.3 Gedachte achter de in scope genomen onderzoeksvariabelen

In paragraaf 1.3.2 van dit onderzoek komt de afbakening op het gebied van de data aan bod. In deze huidige paragraaf staan we echter stil bij de in beschouwing genomen onderzoeksvariabelen, de gedachtegang hierachter, en de mogelijke consequenties van deze keuze voor dit, of verder onderzoek.

Alvorens met dit onderzoek werd begonnen is er enkele jaren praktische ervaring opgedaan met kredietbeoordelaars en de kredietrapporten welke zij verstrekken. Hierbij valt te denken aan bedrijven als: Dun & Bradstreet, Euler Hermes, Creditsafe, Graydon, etc..... Opvallend hierbij was dat zij allen in hun rapporten verwijzen naar een aantal specifieke parameters voor hun kredietbeoordeling en zo ook in hun kredietwaardigheidsrapportages voor verscheidene ondernemingen. Ook is er gekeken naar informatie die publiekelijk voor handen is. Een variabele die niet, of moeilijk te verkrijgen is doet in dit onderzoek immers de uiteindelijke praktische toepasbaarheid tekort. Jaarlijks dienen bedrijven, afhankelijk van de rechtsvorm, bepaalde financiële gegevens te deponeren bij de Kamer van Koophandel. Deze gegevens zijn ook veelal beschikbaar in de bovengenoemde kredietbeoordelingsrapporten.

Tijdens het vooronderzoek naar de beschikbare variabelen is gauw gebleken dat er in de betreffende doelgroep veelal BV's aanwezig zijn. De vertegenwoordiging door BV's bleek 87,5% van de steekproef (n=120). Deze rechtsvorm is verplicht de cijfers te deponeren, echter de hoeveelheid informatie gerapporteerd is afhankelijk van de grootte van een bedrijf. Zo is bijvoorbeeld

gebleken dat de winst en/of omzet enkel in respectievelijk 14,2% en 5% van de gevallen werd vermeld.

De preparatie voor onderzoek behelsde ook vooronderzoek naar correlatie tussen beschikbare variabelen. Beperkt beschikbare variabelen zijn in dit onderzoek uitgesloten en praktische kennis heeft ertoe geleid dat er in eerste instantie met de volgende variabele in dit onderzoek zal worden rekening gehouden: current-ratio, werkkapitaal, solvabiliteitsratio, eigen vermogen, aantal werknemers, 1 cijferige postcode, provincie en jaar van oprichting van een onderneming. Al deze variabelen zijn, voor zover gedeponereerd bij de Kamer van Koophandel, beschikbaar voor onderzoek. Zo ook middels de databronnen van eerdergenoemde bedrijven.

1.1.4 Leeswijzer

Dit rapport kent een scheiding in 6 delen welke gerelateerd zijn aan de wijze waarop de loop van dit onderzoek zijn weg baande. In respectievelijke volgorde zijn de delen als volgt te beschrijven:

- In het 1e hoofdstuk komt de inleiding aan bod. Hierin komt de introductie en motivatie voor het onderzoek naar voren, dit samen met de centrale onderzoeksvraag, relevantie, onderzoeksdoelstelling en methode van aanpak.
- In hoofdstuk 2 vindt er een verdere oriëntatie/analyse van het probleem plaats met betrekking tot de doelstelling, het conceptueel model, variabelen en definities.
- Hoofdstuk 3 is het hoofdstuk waarin analyse van binnen het onderzoek verder wordt uitgewerkt. Hierin komen voornamelijk de bevindingen en deelconclusies verder aan bod.
- In hoofdstuk 4 zijn de resultaten/conclusies en behandeling van de hypothesen terug te vinden samen met enkele aanbevelingen.
- In respectievelijk hoofdstuk 5 & 6 vinden we een methodologische reflectie terug, samen met de in dit onderzoek gebruikte referenties.

1.2 Relevantie

De relevantie van dit onderzoek kan op 2 wijzen worden bekeken, vanuit het perspectief van wetenschappelijke relevantie en vanuit het perspectief van praktische relevantie. Deze perspectieven worden in de hierna volgende paragrafen nader belicht.

1.2.1 Praktische relevantie

De uitkomst van dit onderzoek geeft ons mogelijk meer en beter inzicht in de invloed van verscheidene variabelen op het te verwachten betaalgedrag van afnemers. Gebaseerd op de onderzoeksresultaten kan de beoordeling van financieel risico bij bedrijven, door bedrijven mogelijk beter worden beoordeeld en het risico op betalingsvertraging worden beperkt. Wanneer een bedrijf gebruik maakt van de onderzoeksuitkomsten dan zou dit kunnen leiden tot een financieel voordeel door bijvoorbeeld verlaging van risico door verhoogd inzicht, lagere voorzieningen voor slechte debiteuren, lagere afschrijvingen en hiermee uiteindelijk verhoging van operationele winsten en verbetering van de kasstromen. Dit kan ertoe leiden dat een bedrijf haar marktwaarde zal kunnen verhogen.

Vanuit een ander zichtpunt kan dit onderzoek zorgen voor een beter begrip van de factoren welke binnen de onderzoeksdoelgroep het beste het aanwezig risico capteren en hiermee het beste zichtbaar maken of er sprake is van een gewenst financieel risico. Bedrijven zelf zouden hiermee dan ook hun eigen risico profiel kunnen beoordelen en op deze “KPI” kunnen sturen. Ergo, de test op de aanwezigheid van bepaalde variabelen en hoogte hiervan maakt het voor ons mogelijk een voorspelling te doen over mogelijk aanwezig risico geuit in betaalgedrag en geeft ons een specifieke aanvulling op bestaande modellen om de kredietwaardigheid in te schatten van bedrijven.

1.2.2 Theoretische relevantie

Modellen (tools) voor risicobeheersing als creditscoring zijn al sinds de jaren 50 bekend. Door middel van gebruik te maken van statistische methoden worden modellen gecreëerd op basis van historische data. Deze modellen kunnen “in de markt” worden gebracht door verschillende bedrijven en worden toegepast voor risicobeperking, maar is er zo werkelijk sprake van risico beperking? De mate van het risico beperkende karakter van creditscoringsmodellen is iets dat binnen dit onderzoek geraakt zal worden. We zagen tijdens vooronderzoek dat vele bedrijven de beoordelingen vanuit partijen als een Creditsafe, Dun and Bradstreet, Graydon, etc... als te optimistisch beoordelen. Anderzijds zien we artikelen, waarbij er wordt gewezen op het belang van up-to-date info/onderzoek voor bepaling van profielen. Dit dient op recente data te zijn gebaseerd, met hierin opgenomen sets met data van goede en slechte economische tijden. Ook is een goede aansluiting vanuit de sample op het uiteindelijke profiel van de doelgroep van groot belang voor het maken van een juiste creditscoring inschatting. Zo ook om zo “selection bias” te voorkomen. Een juiste representativiteit vanuit historische data, evenals mogelijk gewijzigde relaties tussen potentieel belangrijke factoren dienen te zijn meegenomen en te worden geactualiseerd indien nodig. Wanneer de manier van acteren in de markt wijzigt, omdat het bijvoorbeeld mak-

kelijker geaccepteerd wordt wanneer een bedrijf failliet is gegaan, dan dient dit in het model te worden/zijn verdisconteerd (Mester, 1997). We onderzoeken in dit onderzoek welke variabelen er voor organisaties in scope genomen voor dit onderzoek werkelijk significant toe doen (representativiteitsverhoging ten opzichte van de meer algemeen gehanteerde modellen).

Dit onderzoek geeft ons de gelegenheid om een model voor creditscoring op te zetten, welke gebaseerd is op actuele data, representatief voor een specifieke doelgroep. Het onderzoek is hiermee een aanvulling op eerder gelijksoortig onderzoek, waarmee er een verdere verfijning kan worden bewerkstelligd op het gebied van het risico op vertraagde betaling door debiteuren. Onder voorwaarden zouden als gevolg uitkomsten van dit onderzoek, en de indicaties van generaliseerbaarheid, kunnen worden benut voor verdere generalisatie dan de doelgroep als nu in scope genomen.

1.3 Methode van aanpak & Theoretisch referentiekader

Voor dit onderzoek nemen we een sample dataset van Nederlandse F-gas gecertificeerde bedrijven in scope. Het onderzoek vindt plaats in de periode november 2012 – mei 2013. Om dit onderzoek goed invulling te kunnen geven is er tevens gezocht naar uitbreiding van het referentiekader in relatie tot het onderzoeksonderwerp. Dit vooronderzoek zal in deze paragraaf hieronder (opgesplitst in delen) verder aan bod komen.

1.3.1 Creditscoring, een korte introductie

Creditscoring was geïntroduceerd in de jaren 40 (19^e eeuw). Sinds de jaren 60 (19^e eeuw) is er meer aandacht voor het beoordelen van (leveranciers)kredieten, vanwege de sterke economische groei in voorgaande decennia. Het werd gezien als een belangrijke manier om de kasstromen te verbeteren en collectie risico's te beperken. Beter management beslissingen konden worden genomen dankzij de aandacht op creditscoring, verschillende technieken om tot scoring te komen werden uitgevonden, waarbij de focus lag op het determineren van goede versus slechte klanten in termen van risico op wanbetaling. Creditscoring werd in scope genomen voor de meer generieke en breed bediscussieerde discriminatie en classificatie problemen (Anderson, 1984; Dillion & Goldstein, 1984; Hand, 1981; Johnson & Wichern, 1998; Morrison, 1990).

Creditscoring is een tool welke al veel gebruikt werd in de bankensector, waardoor er op meer eenduidige, lees uniforme, wijze leningen kunnen worden verstrekt en risico's worden genomen op basis van vooraf vastgestelde criteria, een zogenaamde grenswaarde, waarbinnen men wenst te werken. Doordat deze methode van werken ook breder toepasbaar is kan deze methodiek ook worden ingezet voor bijvoorbeeld commerciële handelsondernemingen die op uniforme/eenduidige wijze risico onder afnemers wensen te classificeren.

In het algemeen zijn er twee essentiële tools voor lineaire statistiek, discriminant analyse (LDA) en logistische regressie (LR)¹, welke beide meest gebruikt worden om tot creditscoring modellen te komen (Lee, Chiu, Lu, Chen, 2002). LR is gerezen tot de voorkeurstechiek wanneer het aankomt op het voorspellen van dichotome uitkomsten (goed/slecht) (Lee, Jo & Han, 1997). Harrel and Lee (1985) vonden uit dat LR net zo efficiënt is als de LDA aanpak.

Recente ontwikkelingen introduceren meer geavanceerde methoden om tot creditscoring “algoritmes” te komen. Dit mede dankzij de technologie, welke het mogelijk maakt om computers geavanceerde calculaties en simulaties te laten uitvoeren/toetsen. Een van die methode is het gebruik van neural networks (NN). NN hebben aangetoond betere creditscoring capaciteiten te bezitten dan LR en LDA (Desai, Conway, & Overstreet, 1997; Desai, Crook & Overstreet, 1996; Jensen, 1992; Piramuthu, 1999; West, 2000). De vaak gehoorde kritiek is echter dat deze methode een lange trainingsperiode vergt voor bepaling van de optimale netwerk topologie en daardoor gelimiteerd is in praktische toepassing (Chung & Gray, 1999; Craven & Shavlik, 1997).

Datamining (DM) is de meest recente ontwikkeling op het gebied van creditscoring. Deze techniek zoekt kennis in de beschikbare database(s) door systematisch te zoeken naar onderliggende patronen en relaties. Volgens Lee, Chiu, Chou, Lu (2006) kunnen er twee categorieën worden gemaakt: methoden en technologieën. Volgens Curt (1995) bestaat de methode uit data visualisatie, machine leren, statistische en deductieve technieken. Applicaties die deze methoden gebruiken kunnen worden gerubriceerd als classificatie, voorspelling, clustering, opsomming, modeleren van afhankelijkheidstoetsen en sequentiële analyse (Fayyad et al., 1996). Het deel aangegeven als technologisch bestaat uit technieken als statistische methodes, neural networks, beslisbomen, genetische algoritmes, etc... (Lee, Chiu, Chou, Lu, 2006). Binnen DM kennen we onder meer de classificatie en regressie beslissingsbomen (CART) en (CHI-kwadraat) automatische interactie detectie (CHAID). Deze technieken lijken in staat betere modellen en resultaten te produceren, vergen minder (trainings)tijd dan NN, maar vergen ook de nodige data in grote aantallen, om tot goede resultaten te komen. Beslisbomen als CART hebben bewezen uiterst effectief te zijn in forecasting en classificatie problemen (Chai et al., 1996; De Gooijer et al., 1998; Friedman and Roosen, 1995; Griffin et al., 1997 Kuhnert et al., 2000; Lewis and Stevens, 1991; Nguyen-Cong et al., 1996; Ohmann et al., 1996).

Analytische resultaten demonstreren volgens Lee, Chiu, Chou, Lu (2006) dat DM (onder andere CART) betere resultaten levert dan LDA, LR en NN in termen van accuratesse en misclassificatie problemen/kosten.

¹ NB: er is sprake van een logistische regressie analyse, zodra de afhankelijke variabele van het dichotome karakter “goed vs. fout”, “1 of 0”, “ja of nee”, etc... is.

1.3.2 Enkele statistische methoden verder belicht

Lineaire Logistische Regressie (LR)

Dit is een breed gebruikte en gangbare techniek om de kans op dichotome resultaten in te schatten ($Y=0$ of $Y=1$), waarbij als input een aantal potentiële, relevante predictors worden ingegeven. Transformatie binnen de formule, naar een “linear gegeven”, maakt het mogelijk de impact op dichotome vraagstukken te duiden/meten. In formulevorm toont LR zich als volgt (Yap, Ong, Husain, 2011):

$$\log \left[\frac{p(Y=1)}{1-p(Y=1)} \right] = \alpha + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k$$

Waarbij $p(Y=1)$ de kans is op de bepaalde uitkomst.

Odds ratio

De odds ratio is een methode te gebruiken om zicht te geven op verhoudingen na metingsresultaten zijn verkregen. Hiermee kunnen we resultaten van/voor variabelen beter interpreteren en duiden wat de kans is dat een situatie zal kunnen voorkomen en hoe dit zich volstrekt. Een voorbeeld van het marginale effect, of de gewogen invloed, welke voor interpretatie kan worden benut illustreren we middels hieronderstaand voorbeeld, waarbij we voortgaan op de hierboven getoonde LR formule:

- Stel: $\beta_2 = 0,3$
- Dat betekent dat de $\log \left[\frac{p(Y=1)}{1-p(Y=1)} \right]$ met 0,3 toeneemt wanneer X_2 met 1 toeneemt. In termen van kans verhoudingen (odds ratio) betekent dit dat kans op $Y=1$ versus kans op $Y=0$ toeneemt met $e^{0,3}$. Ofwel, odds op $Y=1$ neemt toe met $(e^{0,3}-1)*100\%$.

Beslisbomen (CART & CHAID)

Een beslisboom bestaat uit een combinatie van regels voor het segmenteren van een populatie aan de hand van relevante variabelen. Een beslisboom biedt mogelijkheid aan de hand van kansbepaling data te onderscheiden naar specifieke groepen. Veel gebruikte algoritme voor het creëren van een beslisboom zijn de CHI-square Automatic Interaction Detection (CHAID) en Classification Regression Trees (CART). CART gebruikt gini (hoe vaak zou een willekeurig gekozen element incorrect gelabeld worden aan de hand van de distributie van labels in een dataset)². CHAID gebruikt de CHI-kwadraat toets als splitsingscriteria (Berry & Linoff, 2004). CHAID zoekt naar interacties door toetsing van relaties tussen variabele en uitkomst.

Bepaling van de “cut off score”

Volgens Siddiqi (2005), kan deze threshold bepaald worden door de waarde van de Kolmogorov Smirnov toets ofwel k-s test. Hierbij word het verschil in twee verdelingen gemeten (goede betaler versus wanbetaler). De hoogste score toont de cut off waarde en daarmee bijvoorbeeld het minimaal aanvaardbare risico niveau. In dit onderzoek is echter gekozen voor een meer prakti-

² http://en.wikipedia.org/wiki/Decision_tree_learning

sche benadering. Ondernemingen betalen op tijd, wanneer zij binnen de gestelde termijn betalen, te laat wanneer er sprake is van een overschrijding van de betaaltermijn. Als variant hierop is er ook een analyse mogelijk waarbij de cutoff is gebaseerd op een zogenaamde 10 dagen “Days of Grace”, wat praktisch impliceert dat pas na 10 dagen wordt gesteld dat een betaling vertraagd is. In de praktijk ziet men namelijk met regelmaat dat betalingen minder dan 10 dagen vertraagd niet als ernstig worden ervaren.

Enkele relevante foutsoorten

Binnen de statistische methoden eerder beschreven bestaat er een kans op fouten, en dan met name de fouten als gevolg van verkeerde classificatie en bijbehorende “faalkosten”. Eerder, in paragraaf 1.1, werd hier al naar gerefereerd. We spreken hierbij dan van de zogenaamde fouten van de eerste (I) en de tweede (II) soort. I: een goede betaler wordt geclassificeerd als een wanbetaler. II: een wanbetaler wordt geclassificeerd als een goede betaler. Fouten van de II soort kunnen zeer kwalijke gevolgen hebben naar kosten impact. De kans op misclassificatie is volgens West (2000) 1 – 5 voor respectievelijk fout I – II, waarbij de kosten horende bij de fout II veel hoger zijn dan die bij fout I. LR is meest gevoelig en biedt minste kans op fout type II. Een beslissboom daarentegen geeft de hoogste kans op foutsoort II (Yap, Ong, Husain, 2011). Er dient dan ook op te worden toegezien dat de kans op fout II zoveel mogelijk wordt beperkt, zonder de kans op fout I teveel te doen toenemen. Zie ook onderstaande tabel 2.

Foutsoorten	Classificatie	
	Wanbetaler	Goede betaler
Goede betaler	Foutsoort I	
Wanbetaler	Foutsoort II	

Tabel 2 Foutsoorten

1.3.3 Data verzameling & afbakening

Data is verzameld door gebruik te maken van verschillende bronnen als Dun & Bradstreet en Euler Hermes kredietrapporten. De meest actuele en beschikbare financiële gegevens zijn in het onderzoek in beschouwing genomen (zie ook paragraaf 1.1.3). Hierbij zijn bij de Kamer van Koophandel gedeponeerde jaarcijfers in scope genomen. Deze publieke data bevat informatie aangaande betalingshistorie, wijzigingen in bestuur, balanscijfers, winst en verliesrekeningen, etc.

Voor de selectie van de relevante, economisch actieve, bedrijven is gebruik gemaakt van een selectie op basis van SBI codes. Deze selectie beperkt de sample voor onderzoek tot een populatie van 12.200 bedrijven³. De details hiervan zijn zichtbaar in de tabel 3 hieronder.

³

<https://www.kvk.nl/handelsregister/zoekenframeset.asp?zk=0&url=https://server.db.kvk.nl/ia>

2825	Vervaardiging van machines en apparaten voor industriële koeltechniek en klimaatregeling
331212	Reparatie en onderhoud van machines en apparaten voor industriële klimaatregeling en koeltechniek
332212	Installatie van machines en apparaten voor industriële klimaatregeling en koeltechniek
43221	Loodgieters- en fitterswerk; installatie van sanitair
43222	Installatie van verwarmings- en luchtbehandelingsapparatuur
46692	Groothandel in machines en apparaten voor de warmte-, koel- en vriestechiek
711204	Technisch ontwerp en advies voor elektro-, installatietechniek en telematica
7732	Verhuur en lease van machines en installaties voor de bouw

Tabel 3 SBI codes van in scope genomen bedrijven

STEK registratie informatie geeft inzicht in bedrijven voldoende gecertificeerd om koeltechnische werkzaamheden te mogen doen (F-gas certificatie). Deze verdere restrictie brengt de datasample en hiermee in scope genomen doelgroep verder terug tot een ca. 1800 bedrijven.

De beschikbare dataset, welke als steekproef is gebruikt in dit onderzoek beperkt zich tot een steekproefgrootte van ca. 120 bedrijfsrapporten, van bedrijven welke voldoen aan bovenstaande criteria. De bedrijfsrapporten bevatten de data als getoond in de volgende tabel 4.

Aantal werknemers		
Adres	Ernstig negatieve gebeurtenis	Totaal langlopende passiva
Land moedermaatschappij	Balansdatum	Totaal passiva
Oprichtingsjaar	Current Ratio	Totaal vlottende activa
Plaats - D&B	Geplaatst kapitaal	Totaal vlottende passiva
Postcode - D&B	Immateriële activa	Vaste activa
Provincie	Kostprijs van de omzet	Vorig netto eigen vermogen
Rechtsvorm	Netto Eigen Vermogen - D&B	Vorig werkkapitaal
Type lokale activiteitencode	Omzet - D&B	Vorige balansdatum
Bedrijf inactief indicator	Ouderdom balans (maanden)	Werkkapitaal
Betalingen in dagen vertraagd	Totaal activa - D&B	Winst/verlies voor belastingen

Tabel 4 Datavelden beschikbaar in steekproef sample

1.3.4 Methodologische aanpak en onderzoeksplanning

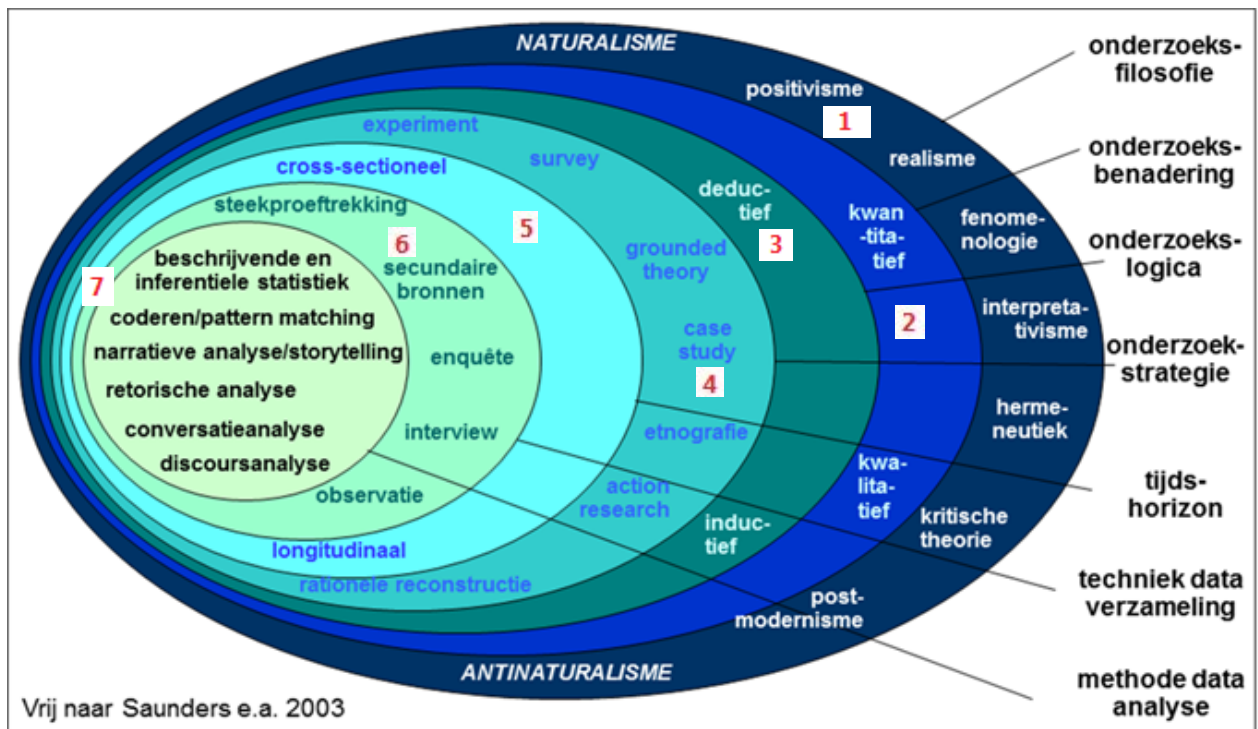
Om dit onderzoek uit te kunnen voeren is de volgende route bewandeld. Er is kwantitatief onderzoek uitgevoerd. Op deze wijze zijn de variabelen met significante invloed blootgelegd door middel van analyses uit te voeren op de beschikbare dataset. Hiervoor is gebruik gemaakt van tools als Excel en SPSS, voor het maken van regressie-/correlatie analyses en het voorbereiden van de datasets (beschrijvende statistiek). De “traditionele” logistieke regressie analyse (LR) geeft ons hierbij inzicht in “de invloed van X op Y”, waarbij we X proberen te verklaren en relaties aantonen. Wat de relevante “X en Y” zijn in dit onderzoek wordt meer duidelijk gemaakt in het conceptueel model gebruikt binnen dit onderzoek. De correlatie analyse geeft dan vervolgens het verband weer, ofwel de samenhang, tussen 2 of meerdere variabelen. Hiermee zien we de mate waarin deze “meebewegen” in positieve of negatieve zin. Door DM technieken als CART en CHAID is getracht het aantal variabelen verder te reduceren naar een aantal beslissende factoren, waarmee de onderliggende structuur van een groep van items verder is onderzocht (op onderliggende patronen en correlaties). Dit geeft ons inzicht in, respectievelijk, de te beschouwen “beslisbomen” en mogelijke correlatie in de observaties. In

paragraaf 2.4.1 zullen de gebruikte onderzoeksinstrumenten nog eens worden benoemd.

In aanvulling op bovenstaande is tijdens dit onderzoek gebruik gemaakt van een zogenaamde controlegroep. Dit houdt in dat de data a-select is opgedeeld in 2 delen, waarbij het ene deel is gebruikt voor de verschillende analyses en bij het andere deel is getoetst of de uitkomst van analyse de verwachte resultaten levert. De verhouding controlegroep (test) vs. trainings-/analyse groep was hierbij respectievelijk 30/70.

Grafisch weergegeven in de volgende figuur “vrij naar Saunders” is voor en tijdens dit onderzoek de volgende, overwegend naturalistische, weg bewandeld:

- 1 Vanuit een positivistische insteek is het onderzoek aangevangen, om zo op basis van vatbare feiten de case te kunnen opbouwen
- 2 Er is gekozen voor een, met name, kwantitatieve benadering om zo de nodige data boven water te krijgen, en hier conclusies op te kunnen baseren. Het kwalitatieve deel van dit onderzoek toont zich bijvoorbeeld binnen het theoretisch referentiekader, dat is benut om een voorselectie van de te onderzoeken variabelen te maken. Maar ook binnen de evaluaties van de uiteindelijke conclusies en analyses
- 3 Het vervolgens deductieve onderzoek heeft kwantificeerbaar zaken aan het licht gebracht,
- 4 in de vorm van een case study zijn deze gegevens in beschouwing genomen (een case study, omdat verschillende cases, zijnde jaarcijfers van verschillende bedrijven zijn bestudeerd), waarna
- 5+6 op basis van cross-sectioneel onderzoek zijn de datasets statistisch geanalyseerd door middel van analyse van de steekproef hiervoor gebruikt, wat ons de gelegenheid heeft gegeven om,
- 7 een beschrijving te geven van de patronen welke zijn geconstateerd.

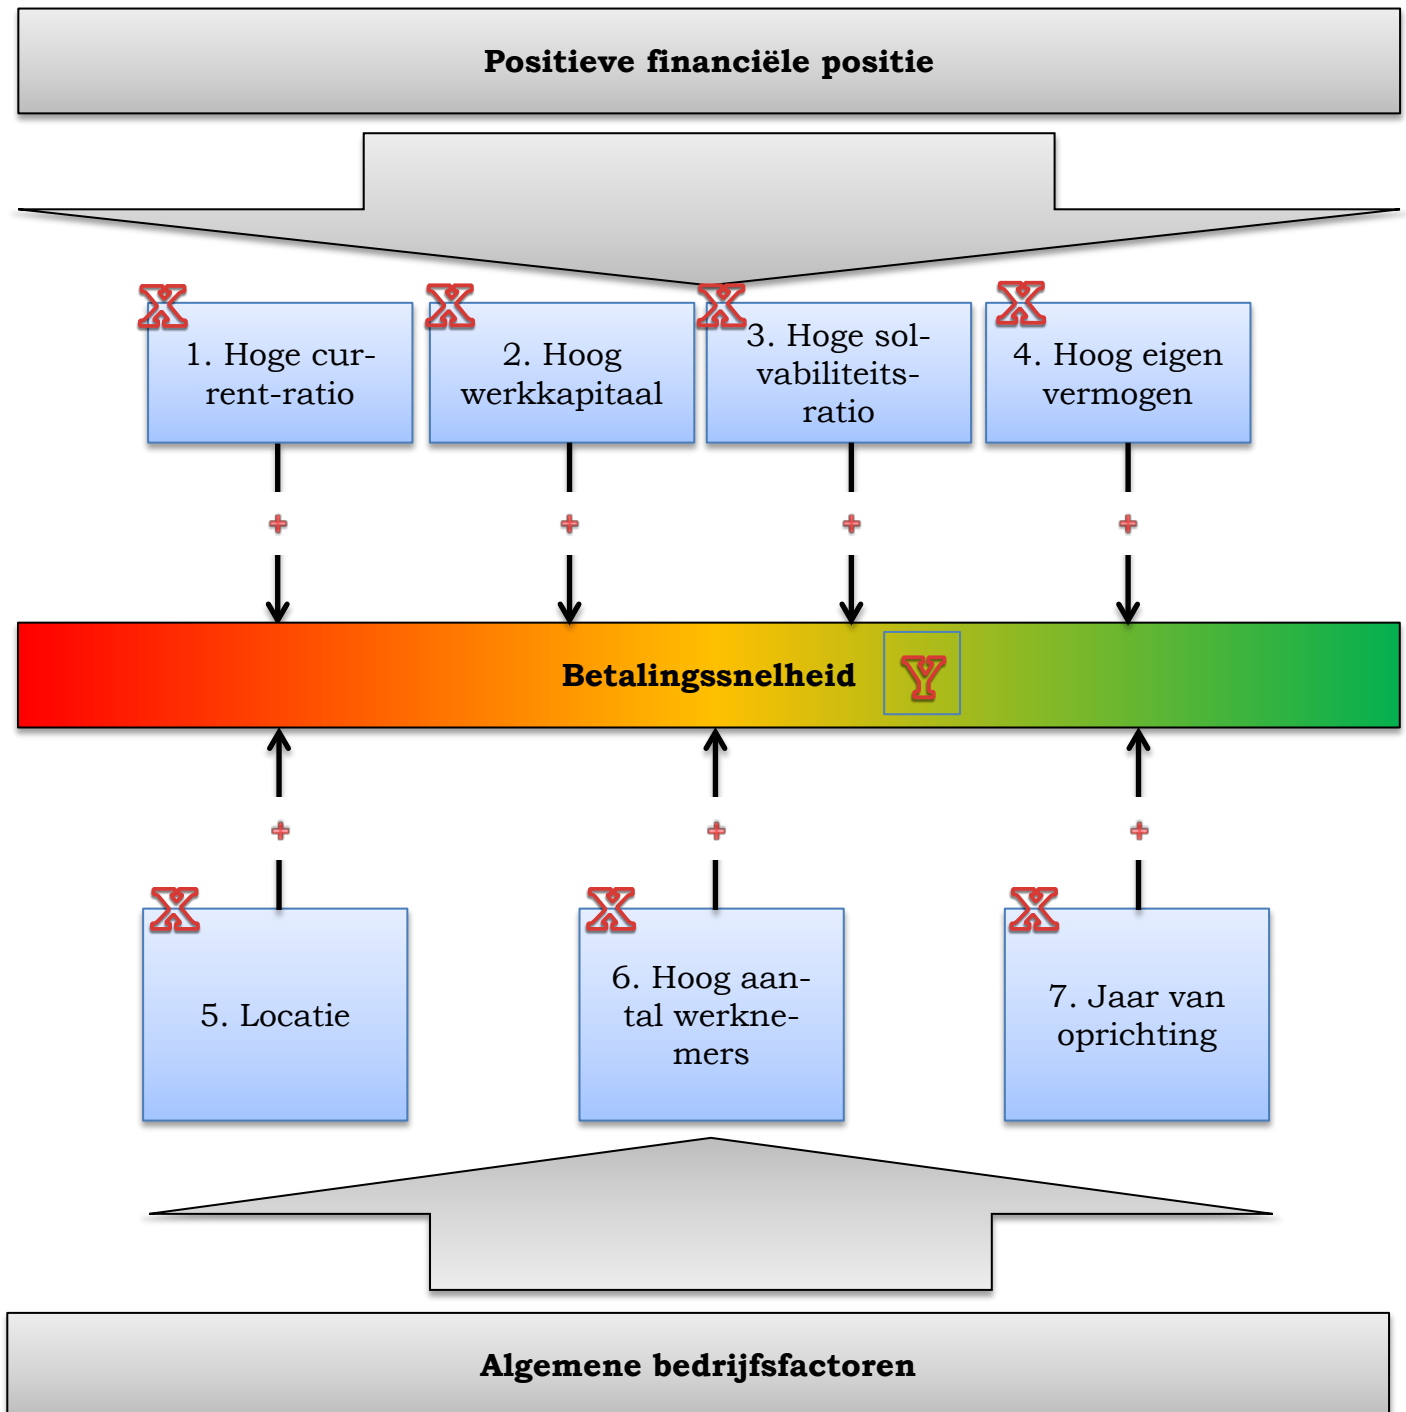


Figuur 1 Onderzoeksinsteeek

2 Onderzoeksontwerp

2.1 Conceptueel model

Om zicht te geven op de in dit onderzoek verwachte invloeden van verschillende oorsprong is een conceptueel model opgezet dat de invloeden als in dit onderzoek verwacht illustreert, zie hiervoor de volgende figuur.



Figuur 2 Conceptueel model voor onderzoek

2.2 Doelstelling

Het bepalen van de meest invloedrijke variabele, welke kan worden beschouwd als sterke predictor en/of modificerende factor voor de mate van betalingssnelheid van potentiële afnemers.

2.3 Hypothesen

De hypothesen in dit onderzoek opgenomen zijn in deze paragraaf getoond. Binnen het conceptueel model zijn deze hypothesen ook zichtbaar en later in paragraaf 2.4 worden deze nader toegelicht.

- | | |
|---------------------|--|
| Hypothese 1. | X1 , Een hoge current-ratio voorspelt een hoge betaalsnelheid. |
| Hypothese 2. | X2 , Een hoog werkkapitaal voorspelt een hoge betaalsnelheid |
| Hypothese 3. | X3 , Een hoge solvabiliteitsratio voorspelt een hoge betaalsnelheid |
| Hypothese 4. | X4 , Een hoog eigen vermogen voorspelt een hoge betaalsnelheid |
| Hypothese 5. | X5 , De locatie van een bedrijf is bepalend voor het betaalgedrag. |
| Hypothese 6. | X6 , Een bedrijf met een hoog aantal werknemers betaalt sneller. |
| Hypothese 7. | X7 , Bedrijven die langer bestaan betalen sneller. |
| Hypothese 8. | Y , De te verwachten betalingssnelheid van een onderneming laat zich meest significant voorspellen, lees beïnvloeden, door één of een combinatie van de in hypothese 1-7 genoemde variabelen. |

2.4 Begripsbepaling en “empirische vertaling”

Financiële positie, uitgedrukt in enkele variabele

In dit onderzoek wordt er gewerkt met de financiële gegevens, zoals verplicht jaarlijks door ondernemingen te deponeren bij de Kamer van Koophandel. Deze informatie is gebruikt om de financiële positie van een onderneming te kunnen bepalen. De hierna volgende variabelen zijn dan ook geselecteerd om de financiële positie van een onderneming op vergelijkbare basis te onderzoeken ten behoeve van de bepaling van de invloed van deze op het betaalgedrag. Achter elke variabele, welke in respectievelijke volgorde correspondeert met eerdergenoemde hypothese, staat beschreven welke impact er wordt verwacht op de uiteindelijk te verklaren variabele (Y).

In Paragraaf 2.4.1 staan de gehanteerde onderzoeksinstrumenten beschreven, als ook in paragraaf 1.3.4 reeds naar gerefereerd en eerder in hoofdstuk 1 in meer detail toegelicht.

X1. Current-ratio, de verhouding tussen vlottende activa en vlottende passiva op de balans van de onderneming.

In dit onderzoek is verondersteld dat een hoge waarde X_1 een positieve invloed heeft op de betalingssnelheid.

X2. Werkkapitaal, vlottende activa op de balans minus het kort vreemd vermogen.

In dit onderzoek is verondersteld dat een hoge liquiditeit een positief effect heeft op het betalingssnelheid. Middels de variabele X_2 is de liquiditeit als absolute waarde meegenomen in dit onderzoek, waarbij is verondersteld dat een hoog werkkapitaal een positief effect heeft op de betalingssnelheid.

X3. Solvabiliteit, het aandeel eigen vermogen ten opzichte van het totale balans vermogen van een onderneming.

Verondersteld wordt dat een hoge solvabiliteitsratio (X_3) een positieve invloed heeft op de betalingssnelheid van een onderneming.

X4. Eigen vermogen, activa op de balans minus het vreemd vermogen.

In dit onderzoek is verondersteld dat een hoge solvabiliteit een positief effect heeft op het betalingssnelheid. Middels de variabele X_4 is de solvabiliteit als absolute waarde meegenomen in dit onderzoek, waarbij is verondersteld dat een hoog eigen vermogen een positief effect heeft op de betalingssnelheid.

Algemene bedrijfsfactoren, uitgedrukt in enkele variabele

Omdat niet alle bedrijven een gelijke deponeringsplicht kennen, kan het zijn dat bepaalde financiële gegevens niet voor handen zijn. Toch zijn ook deze, vaak kleinere, bedrijven mee in scope genomen. Onderstaande variabelen bieden ons dan ook aanvullend inzicht naar hun relatie ten opzichte van de betalingssnelheid van deze (vaak) kleinere bedrijven.

X5. Locatie, is de provincie en/of 1-cijferig postcode gebied waar de onderneming is gevestigd.

X6. Medewerkers, het aantal medewerkers actief bij het bedrijf.

Verondersteld is, dat het in dienst hebben van veel werknemers een positieve impact heeft op de betalingssnelheid van een bedrijf.

X7. Oprichting, de datum waarop het bedrijf zich heeft ingeschreven bij de kamer van koophandel.

Verondersteld is dat de mate van ouderdom van een bedrijf een positieve invloed heeft op de betalingssnelheid.

De te voorspellen waarde

Y Betalingssnelheid, de snelheid (uitgedrukt in dagen) waarmee facturen na vervaldatum worden voldaan. Dit kan worden weergegeven als: betaling op tijd (binnen termijn), of vertraagde betaling (buiten termijn).

2.4.1 Onderzoeksinstrumenten

De volgende databronnen en onderzoeksinstrumenten zijn gehanteerd:

Data verzameling: Database Euler Hermes en Dun & Bradstreet

Data preparatie: Excel en SPSS

Analyses d.m.v.: Excel en SPSS (logistieke) regressie, correlatie en CART analyses.

SPSS Answer Trees ten behoeve van Chi-Square Automatic Interaction Detection Tests.

3 Empirische bevindingen, analyse en deelconclusies

3.1 Fase 1, descriptieve- & (logistische) regressie analyse

De beschikbare data is geanalyseerd met behulp van zogenaamde beschrijvende statistiek. Op deze wijze is inzicht gekregen in de bruikbaarheid van de data en mogelijke correlaties tussen verschillende variabelen. Tijdens deze fase zijn een aantal cruciale zaken aan het licht gekomen, zoals de soms afwezige populatie van velden. Later in dit rapport zal meer inzicht worden gegeven in hoe hiermee is omgegaan binnen de CHAID analyse(s). Vooral nog heeft deze constatering gezorgd voor verminderd bruikbare sets uit de data. Daar waar (significante) correlatie werd gezocht over de sets van datalijnen, daar zijn lijnen met lege velden uitgesloten, waardoor de totale steekproefgrote afneemt van 120 naar n=95.

Om te komen tot de uiteindelijke gewenste $Y =$ snelheid van betalen, is er een transformatie gebeurd, waardoor er een tweetal nieuwe variabelen zijn gecreëerd, te weten: betaling OK vs. niet OK en een variant hierop, waarbij de betaling OK is wanneer deze binnen 10 dagen geschied.

Outliers met een afwijking van driemaal de standaarddeviatie zijn uitgesloten van de analyse, dit had geen impact op de gegeven dataset, welke gelijk bleef in grootte. De analyse is gezien de condities van toepassing mogelijk onderhevig aan “Omitted Variable Bias”⁴, dit is zoveel mogelijk voorkomen door belangrijke causale factoren in beschouwing te nemen en door rekening te houden met onder-/over estimatie van factoren en correlaties. Dit komt tevens aan bod in het latere reflectie hoofdstuk in dit rapport evenals het voorbehoud voor “non-stationary effects”, waarbij wordt verondersteld dat “het effect” ergens sterk is, maar niet elders. Dit kan bijvoorbeeld een gevolg zijn van mogelijke interactie effecten. Multicollineariteit is vermeden door gepaste variabelen selectie en correlatie analyses, als ook later beschreven in dit rapport. Alle variabelen in scope kennen een normale distributie.

De variabelen, als in dit onderzoek gebruikt, zijn gecodeerd volgens de hierna volgende legenda (tabel 5). Hierbij zijn ook de toelichtingen op enkele gebruikte statistische begrippen opgenomen (tabel 6). Ook is in de figuren 3 & 4 en tabel 7 & 8 hierna, ter illustratie en beeldvorming, meer zicht gegeven op de locatie gerelateerde variabelen en betaalsnelheid.

⁴ http://en.wikipedia.org/wiki/Omitted-variable_bias

Variabele	Definitie
X1_CurRat	Current-ratio , de verhouding tussen vlottende activa en vlottende passiva
X2_WC	Werkkapitaal , vlottende activa op de balans minus het kort vreemd vermogen
X3_Solv	Solvabiliteit , het aandeel eigen vermogen ten opzichte van het totale balans vermogen
X4_EV	Eigen vermogen , activa op de balans minus het vreemd vermogen
X5_Provincie	Locatie , de Nederlandse provincie waar de onderneming is gevestigd
PC1dig	Locatie , het Nederlandse 1-cijferig postcode gebied waar de onderneming is gevestigd
X6_empl	Medewerkers , het aantal medewerkers actief bij het bedrijf
X7_Oprichtingsjaar	Oprichting , de datum (jaar) waarin het bedrijf zich heeft ingeschreven bij de kamer van koophandel
Y_pay_OK_NOK	Betalingssnelheid , de snelheid waarmee facturen worden voldaan (waarbij 1= te laat en 0= binnen termijn)
Y_pay_less10days	Betalingssnelheid , de snelheid waarmee facturen worden voldaan (waarbij 1= buiten 10 dagen na termijn en 0= binnen 10 dagen na termijn)
Y_paymentSPD	Betalingssnelheid , de snelheid (uitgedrukt in dagen) waarmee facturen na vervaldatum worden voldaan


Tabel 5 Legenda voor gebruikte variabelen

Statistisch begrip	Definitie
N Valid	Aantal valide waarnemingen uit de steekproef
N Missing	Aantal missende (niet ingevulde) waarnemingen uit de steekproef
Mean	Gemiddelde van de waargenomen data
Median	middelste waarde van de waargenomen data
Std. Deviation	verschil in waarnemingen (> = > verschil in waarnemingen)
Variance	afwijking van het gemiddelde
Skewness	scheefheid van de waargenomen data (asymmetrie in de verdeling, waarbij een positief teken staat voor vele waarnemingen aan de linkerzijde van een normale verdeling, en een negatieve waarde een opstapeling aan de rechterzijde)
Std. Error of Skewness	Afwijkingen van 2 of meer, geven een waarschijnlijk significante mate van scheefheid aan (geen normale verdeling)
Range	delta tussen de grootste en kleinste waargenomen waarde
Pearson Correlation	correlatie, waarbij -1 = "perfect negatief gecorreleerd" (tegengesteld), +1 = "perfect positief gecorreleerd" (beweegt mee) en 0 = geen statistisch aangetoond verband
Sig. (1-tailed)	Significantie, waarbij 1 berust op toeval en <0,05 significant is (bij 95% betrouwbaarheid)
B	kans op Y=1 (odds-ratio)
S.E	Standard Error, zie ook eerder
Wald	toetsing van significant verband (in dit onderzoek inferieur gezien kleine sample)
df	degrees of freedom --> vrijheidsgraden
Exp(B)	verwachte kans op Y=1 (verwachte/voorspelde odds ratio met model)

Tabel 6 Statistische begrippen

Postcodes in Nederland

- 1000-1999
- 2000-2999
- 3000-3999
- 4000-4999
- 5000-5999
- 6000-6999
- 7000-7999
- 8000-8999
- 9000-9999



Figuur 3 Postcodes in NL



Figuur 4 Provincies in NL

1-cijferige postcode	% volgens KvK	% in steekproef	steekproef vs. KvK
1	14%	10%	70%
2	16%	18%	112%
3	17%	13%	77%
4	9%	12%	138%
5	14%	18%	128%
6	10%	11%	111%
7	9%	11%	120%
8	6%	3%	52%
9	5%	4%	78%

Provincie	% volgens KvK	% in steekproef	steekproef vs. KvK
Groningen	3%	1%	38%
Friesland	3%	3%	89%
Drenthe	3%	3%	107%
Overijssel	6%	7%	114%
Flevoland	2%	1%	51%
Gelderland	12%	13%	106%
Utrecht	8%	9%	111%
Noord-Holland	16%	8%	51%
Zuid-Holland	22%	23%	106%
Zeeland	2%	3%	126%
Noord-Brabant	17%	21%	121%
Limburg	6%	8%	137%

Tabel 7 Spreiding van doelgroep populatie & steekproef over de 1-cijferige postcodes & provincies

Y_pay_OK_NOK

	Frequency	Percent	Valid Percent	Cumulative Percent
Valid ,0	27	22,5	22,5	22,5
1,0	93	77,5	77,5	100,0
Total	120	100,0	100,0	

Y_pay_less10days

	Frequency	Percent	Valid Percent	Cumulative Percent
Valid ,0	59	49,2	49,2	49,2
1,0	61	50,8	50,8	100,0
Total	120	100,0	100,0	

Tabel 8 Betaalgedrag van de steekproef, waarbij 1= te late betaling

Statistics

	X1_CurRat	X2_WC	X3_Solv	X4_EV	X5_Provincie	PC 1dig	X6_empl	X7_Oprichting_sjaar	Y_pay_OK_N OK	Y_pay_less10 days	Y_paymentSP D
N	Valid Missing	100 20	100 20	100 20	120 0	120 0	113 7	118 2	120 0	120 0	120 0
Mean	1,807	755721,550	,071	1121813,910		4,27	53,204	1996,98	,775	,508	12,725
Median	1,350	127880,000	,300	187609,000		4,00	13,000	1998,50	1,000	1,000	11,000
Std. Deviation	1,6747	2207991,987	1,0663	2532943,250		2,210	263,6813	11,165	,4193	,5020	14,3058
Variance	2,805	4,875E+12	1,137	6,416E+12		4,886	69527,824	124,649	,176	,252	204,655
Skewness	2,843	2,997	-5,942	2,505		,296	10,276	-,832	-,1334	-,034	2,560
Std. Error of Skewness	,241	,241	,241	,241		,221	,227	,223	,221	,221	,221
Range	10,4	14366991,0	9,3	13681406,0		8	28000,0	40	1,0	1,0	87,0

Correlations

	Y_pay_OK_N OK	X1_CurRat	X2_WC	X3_Solv	X4_EV	PC 1dig	X6_empl	X7_Oprichting_sjaar
Pearson Correlation	1,000	-,024	,089	,137	,112	-,001	,067	-,077
	-,024	1,000	,498	,339	,343	-,028	-,102	-,312
	,089	,498	1,000	,224	,866	-,136	-,086	-,370
	,137	,339	,224	1,000	,250	,043	,044	-,148
	,112	,343	,866	,250	1,000	-,228	,234	-,420
	-,001	-,028	-,136	,043	-,228	1,000	-,123	,050
	,067	-,102	-,086	,044	,234	-,123	1,000	,045
	-,077	-,312	-,370	-,148	-,420	,050	,045	1,000
Sig. (1-tailed)		,410	,196	,092	,140	,495	,258	,229
	,410		,000	,000	,000	,396	,163	,001
	,196	,000		,015	,000	,094	,204	,000
	,092	,000	,015		,007	,339	,337	,077
	,140	,000	,000	,007		,013	,118	,314
	,495	,396	,094	,339	,013		,118	,333
	,258	,163	,204	,337	,011	,118		,333
	,229	,001	,000	,077	,000	,314	,333	

Tabel 9 Descriptieve & (logistieke) regressie analyse (bivariaat)

We zien in eerder getoonde tabel 8 & 9 dat,

- 77,5% van de doelgroep te laat betaald. 50,8% van de doelgroep betaald meer dan tien dagen te laat.
- Er geen perfecte, direct significante correlatie is tussen op tijd betalen en de in scope genomen variabelen,
- Meest positieve correlatie als verklarende variabelen uit gaat naar X3 (solvabiliteit), X4 (eigen vermogen) en X2 (werkkapitaal), gevolgd door X6 (medewerkers),
- Meest negatieve correlatie uit gaat vanuit X7 (oprichtingsjaar).
- Oprichtingsjaar van een onderneming een significante negatieve (teggengestelde) invloed heeft op werkkapitaal en current ratio (liquiditeit van de onderneming) → jongere bedrijven zijn minder liquide
- Dat de algemene factoren postcode en aantal medewerkers er schijn van geven dat deze het eigen vermogen capteren. Respectievelijk: hogere postcode → lager eigen vermogen, hoger aantal medewerkers → hoger eigen vermogen

Als gevolg van bovenstaande veronderstellen we “omitted variable bias” uit te kunnen sluiten in deze set van variabelen, doordat de correlatie tussen afhankelijke en determinerende variabele voldoende beperkt blijft.

Tussen de voorspellende variabelen onderling zien we significante correlaties in gelijke richting. Latere analyse zal hiervan gebruik maken, doordat samenkomst van variabelen versterkend zal kunnen werken in het bepalen van een mogelijke uitkomst (Y).

Wanneer de hierna volgende tabel 10 in beschouwing wordt genomen, voor betalingen binnen de tien dagen na vervaldatum, dan zien we grotere significantie en beperktere correlatie met betrekking tot Y.

		Correlations							
		Y_pay_less10 days	X1_CurRat	X2_WC	X3_Solv	X4_EV	PC 1dig	X6_empl	X7_Oprichting sjaar
Pearson Correlation	Y_pay_less10days	1,000	,083	,067	,017	,024	-,029	-,099	-,041
	X1_CurRat	,083	1,000	,498	,339	,343	-,028	-,102	-,312
	X2_WC	,067	,498	1,000	,224	,866	-,136	-,086	-,370
	X3_Solv	,017	,339	,224	1,000	,250	,043	,044	-,148
	X4_EV	,024	,343	,866	,250	1,000	-,228	,234	-,420
	PC 1dig	-,029	-,028	-,136	,043	-,228	1,000	-,123	,050
	X6_empl	-,099	-,102	-,086	,044	,234	-,123	1,000	,045
	X7_Oprichtingsjaar	-,041	-,312	-,370	-,148	-,420	,050	,045	1,000
Sig. (1-tailed)	Y_pay_less10days	.	,212	,259	,435	,409	,390	,171	,348
	X1_CurRat	,212	.	,000	,000	,000	,396	,163	,001
	X2_WC	,259	,000	.	,015	,000	,094	,204	,000
	X3_Solv	,435	,000	,015	.	,007	,339	,337	,077
	X4_EV	,409	,000	,000	,007	.	,013	,011	,000
	PC 1dig	,390	,396	,094	,339	,013	.	,118	,314
	X6_empl	,171	,163	,204	,337	,011	,118	.	,333
	X7_Oprichtingsjaar	,348	,001	,000	,077	,000	,314	,333	.

Tabel 10 (logistieke) regressie analyse (bivariaat) voor betalingen buiten de 10 dagen na termijn

Wanneer de variabelen middels een multivariate LR analyseren, dan zien we bij elke variabele toegevoegd de nauwkeurigheid van het voorspellend ka-

rakter van het model toenemen. We zien voor betalingen OK versus NOK en voorspelbaarheid van 100% voor het voorspellen van wanbetaling. Voorspellen van tijdige betaling blijft moeizaam, bij verfijning van het model met gegeven variabele blijft de waarde van correcte voorspelling laag (6,3%). We zien verder dat significante waarden per variabele uitblijven, maar het gehele model een voorspellend karakter heeft voor het voorspellen van late betaling. Gemiddeld gezien wordt met dit model 84,2% correct voorspeld. Zie ook onderstaande tabel 11.

Classification Table^a

Observed		Predicted			
		Y_pay_OK_NOK		Percentage Correct	
		,0	1,0		
Step 1	Y_pay_OK_NOK	,0	1	15	6,3
		1,0	0	79	100,0
Overall Percentage					84,2

a. The cut value is ,500

Variables in the Equation

	B	S.E.	Wald	df	Sig.	Exp(B)	95% C.I. for EXP(B)	
							Lower	Upper
Step 1 ^a								
X1_CurRat	-,141	,188	,560	1	,454	,869	,601	1,256
X2_WC	,000	,000	,481	1	,488	1,000	1,000	1,000
X3_Solv	,244	,227	1,154	1	,283	1,276	,818	1,989
X4_EV	,000	,000	,264	1	,608	1,000	1,000	1,000
X5_nostring_PC1dig	-,005	,131	,001	1	,970	,995	,769	1,287
X6_empl	,015	,016	,884	1	,347	1,015	,984	1,046
X7_Oprichtingsjaar	-,002	,036	,002	1	,962	,998	,931	1,071
Constant	4,883	71,528	,005	1	,946	132,040		

a. Variable(s) entered on step 1: X7_Oprichtingsjaar.

Tabel 11 Samenvatting resultaat Multivariate LR in 7 stappen

Wanneer we op gelijke wijze de uitkomsten beschouwen voor analyse bij betalingsvertraging groter dan 10 dagen, dan zien we een model met een beperkt (gemiddeld 51,6% correct voorspeld) voorspellend karakter en verslechterende significanties. Zie ook tabel 12.

Classification Table^a

Observed		Predicted		
		Y_pay_less10days		Percentage Correct
		,0	1,0	
Step 1	Y_pay_less10days ,0	15	31	32,6
	1,0	15	34	69,4
Overall Percentage				51,6

a. The cut value is ,500

Variables in the Equation

	B	S.E.	Wald	df	Sig.	Exp(B)	95% C.I. for EXP(B)	
							Lower	Upper
Step 1 ^a								
X1_CurRat	,065	,161	,166	1	,684	1,068	,779	1,463
X2_WC	,000	,000	,029	1	,865	1,000	1,000	1,000
X3_Solv	-,003	,207	,000	1	,989	,997	,664	1,497
X4_EV	,000	,000	,009	1	,926	1,000	1,000	1,000
X5_nostring_PC1 dig	-,034	,098	,124	1	,725	,966	,798	1,170
X6_empl	-,001	,002	,308	1	,579	,999	,995	1,003
X7_Oprichtingsjaar	-,003	,022	,023	1	,879	,997	,955	1,040
Constant	6,688	43,154	,024	1	,877	803,005		

a. Variable(s) entered on step 1: X7_Oprichtingsjaar.

Tabel 12 Samenvatting resultaat (>10 dagen) Multivariate LR in 7 stappen

3.1.1 Deelconclusie fase 1, descriptieve- & (logistische) regressie analyse

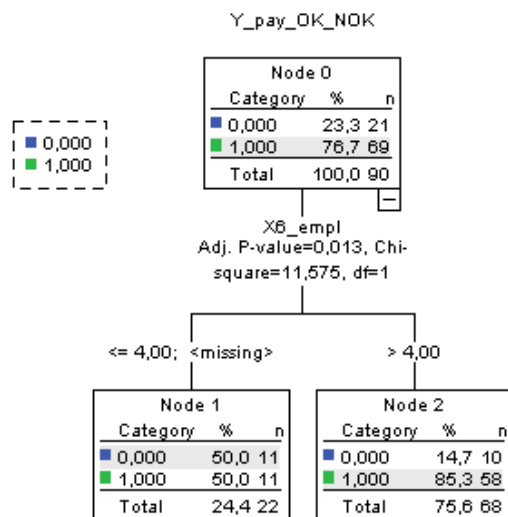
- ✓ De relatief kleine steekproef van n=95 laat geen perfecte, significante correlatie zien tussen snelheid van betalen en de voorspellende variabelen
- ✓ Oprichtingsjaar van een onderneming heeft een significante negatieve (tegengestelde) invloed op werkkapitaal en current ratio (liquiditeit van de onderneming) → jongere bedrijven zijn minder liquide
- ✓ De algemene factoren postcode en aantal medewerkers tonen met hoge mate van waarschijnlijkheid, dat deze het eigen vermogen capteren. Respectievelijk: hogere postcode → lager eigen vermogen, hoger aantal medewerkers → hoger eigen vermogen
- ✓ Multivariate LR toont aan dat voorspelling met een groep van variabele mogelijk is en bij betaling OK versus NOK in 84,2% van de gevallen correcte uitkomst toont.
- ✓ Voorspellen van wanbetaling (100%) blijkt eenvoudiger dan het voorspellen van correct betaaldedrag (6,3%).

3.2 Fase 2, CHAID analyse

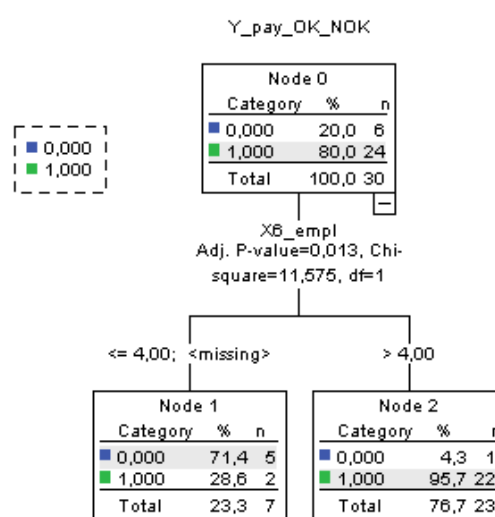
1^e analyse (OK vs. NOK)

De beschikbare data is geanalyseerd met behulp van CHAID op basis van een 95% betrouwbaarheid. Hierbij is proefondervindelijk een model gebouwd, waarbij een beslisboom voldeed aan de voorwaarden dat een “parent node” minimaal 10 cases kent en een “child node” minimaal 5. Na simulatie met een random trainingssample van 70% van de data set is de toetsing gebeurd op een random geselecteerde test set van de overige 30%. De uitkomsten zijn in onderstaande figuren getoond, waarbij:

Variabele	Definitie
Y_pay_OK_NOK	Betalingsnelheid, de snelheid waarmee facturen worden voldaan (waarbij 1= te laat en 0= binnen termijn)



Figuur 5 Training sample CHAID



Figuur 6 Test sample CHAID

We zien dat circa 77% van de bedrijven te laat zal betalen volgens het model. Het aantal medewerkers blijkt volgens deze analyse de sterkst bepalende factor om de kans op slecht betaalgedrag mee in te schatten. Het omslagpunt toont zich hierbij bij 4 medewerkers en bedrijven zonder medewerkers, volgens de Kamer van Koophandel. Het risico op misclassificatie, op basis van toetsing met de testsample, toont zich als weergegeven in de volgende tabel.

Classification

Sample	Observed	Predicted		
		,0	1,0	Percent Correct
Training	,0	11	10	52,4%
	1,0	11	58	84,1%
	Overall Percentage	24,4%	75,6%	76,7%
Test	,0	5	1	83,3%
	1,0	2	22	91,7%
	Overall Percentage	23,3%	76,7%	90,0%

Growing Method: CHAID

Dependent Variable: Y_pay_OK_NOK

Tabel 13 Risico op misclassificatie volgens het CHAID model

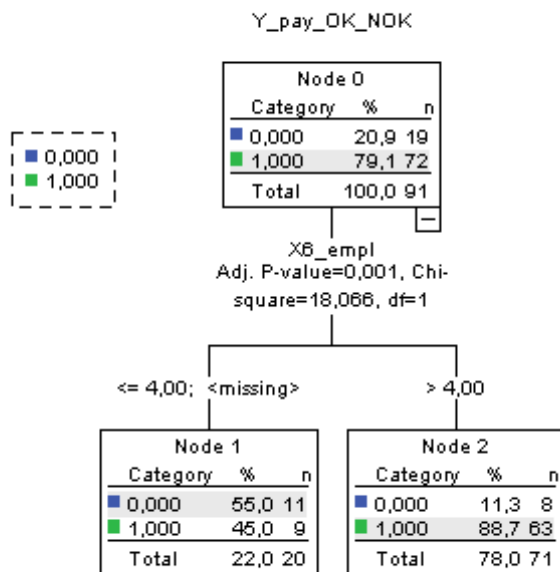
We zien dat de voorspelling in >90% van de gevallen correct bleek. Het blijkt lastiger de correcte inschatting te maken voor bedrijven die wel op tijd betalen, vandaar zoeken we verder in de analyse naar een nauwkeuriger model, waarbij we nota nemen van het gestelde uit eerdere hoofdstukken. We hechten namelijk meer waarde aan de juiste voorspelling van ondernemingen die later betalen gezien de bijbehorende grotere risico's, echter dienen we opportuniteitsverliezen niet te negeren.

2^e analyse (OK vs. >10 dagen)

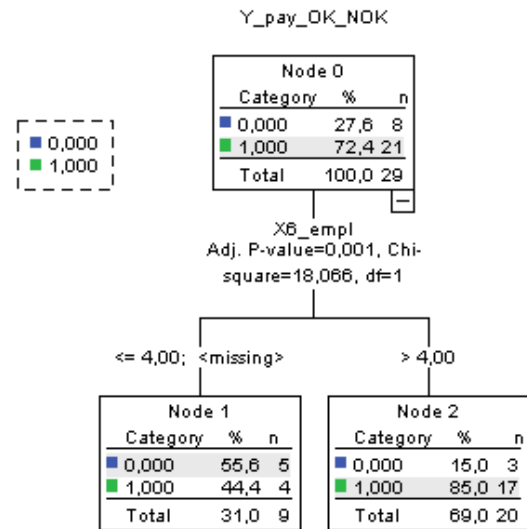
Gelijk als bij de 1^e analyse is nu gekeken naar de betalingen binnen 10 dagen na vervaldatum. Hierbij signaleren we dat de kans op deze vorm van vertraagde betaling zich niet verder laat opsplitsen in een beslisboom doormiddel van de beschikbare variabelen. De kans op deze vorm van vertraagde betaling is met een voorspelbaarheid van 100% in deze toetsing een kans van ca. 51%.

3^e analyse (OK vs. NOK)

Er is uitvoeriger analyse gedaan door middel van exhaustive CHAID op basis van een 95% betrouwbaarheid. Op deze wijze is het model nogeens getoetst en verfijnd. De uitkomst bevestigt eerdere analyse, met licht genuanceerde voorspellingswaarde als in volgende figuur getoond.



Figuur 7 Training Exhaustive CHAID (OK vs. NOK)



Figuur 8 Test Exhaustive CHAID (OK vs. NOK)

Classification

Sample	Observed	Predicted		
		,0	1,0	Percent Correct
Training	,0	11	8	57,9%
	1,0	9	63	87,5%
	Overall Percentage	22,0%	78,0%	81,3%
Test	,0	5	3	62,5%
	1,0	4	17	81,0%
	Overall Percentage	31,0%	69,0%	75,9%

Growing Method: EXHAUSTIVE CHAID
Dependent Variable: Y_pay_OK_NOK

Tabel 14 Risico op misclassificatie volgens het Exhaustive CHAID model

4^e analyse (OK vs. >10 dagen)

Er is uitvoeriger gezocht aan de hand van exhaustive CHAID, echter zonder noemenswaardige verschillen.

3.2.1 Deelconclusie fase 2, (exhaustive) CHAID analyse op basis van een 95% betrouwbaarheid

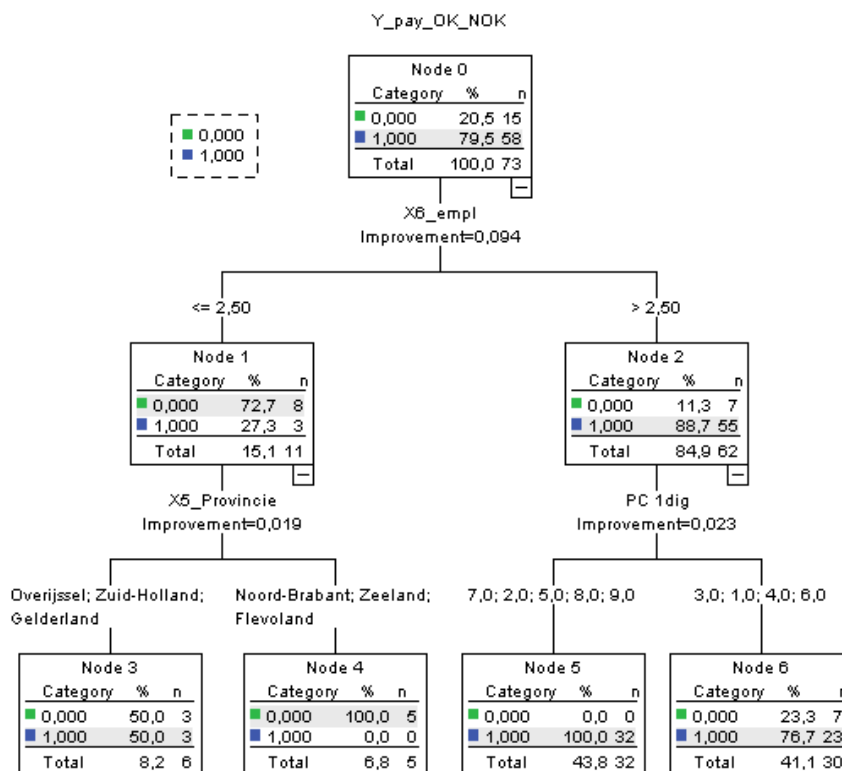
- ✓ We zien dat circa 77-79% van de ondernemingen uit de doelgroep van dit onderzoek te laat betalen.
- ✓ Of een onderneming op tijd of te laat betaald kan worden voorspeld aan de hand van het aantal medewerkers
- ✓ Een bedrijf met <4 medewerkers toont een ca. 45 - 50% kans op verlate betaling

- ✓ Een bedrijf met >4 medewerkers toont een 85 - 89% kans op vertraagde betaling
- ✓ In 90% van de gevallen komt deze voorspelling uit
- ✓ De kans dat een bedrijf later dan 10 dagen na vervaldatum betaald is voor de gestelde doelgroep 51%

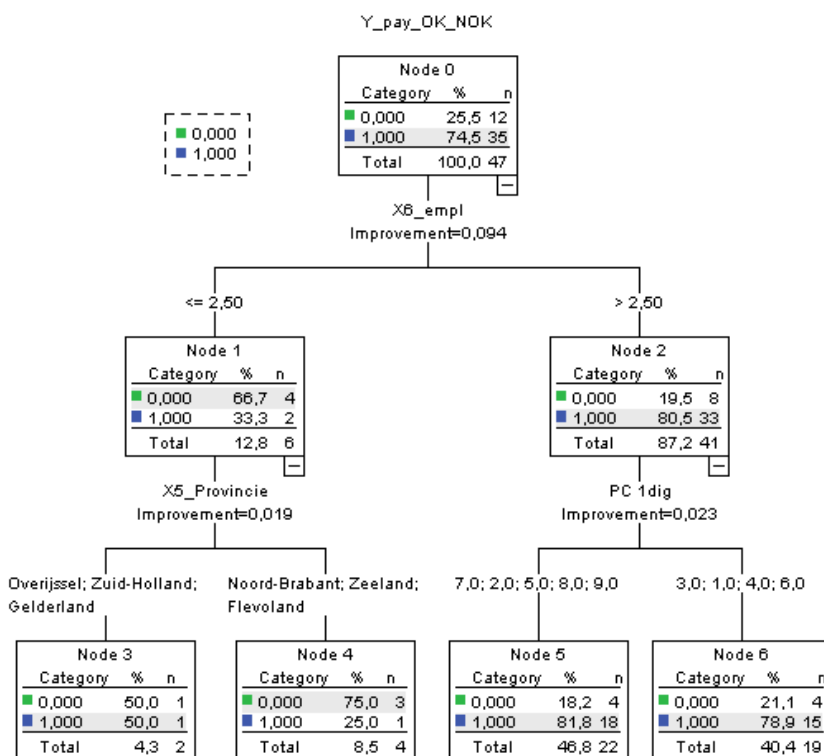
3.3 Fase 3, C(A)RT analyse

Door gebruik te maken van de C(A)RT analyse, op basis van een 95% betrouwbaarheid, is een crosscheck gedaan voordat tot uitspraken over de verklarende variabelen wordt overgegaan. Deze analyse heeft geleid tot het hieronder getoonde model, waarbij ook hier de “parent node” is beperkt tot minimaal 10 cases en minimaal 5 nodes in de “child node”. Voor de Y variabele getoond geld:

Variabele	Definitie
Y_pay_OK_NOK	Betalingsnelheid, de snelheid waarmee facturen worden voldaan (waarbij 1= te laat en 0= binnen termijn)



Figuur 9 C(A)RT Training model (OK vs. NOK)



Figuur 10 C(A)RT Test model (OK vs. NOK)

We zien dat:

- Bijna 80% van de bedrijven te laat betaalt,
- Wanneer een bedrijf minder dan 3 (<2,5) medewerkers heeft, dan is de kans op vertraagde betaling binnen deze groep van 80% ca. 27%
- Wanneer een bedrijf gevestigd is in Overijssel, Zuid Holland of Gelderland, dan is de kans op vertraagde betaling binnen de genoemde restgroep van 27% een 50%.
- Wanneer een bedrijf meer dan 3 (>2,5) medewerkers kent, dan is de kans op vertraagde betaling binnen de groep van ca. 80% een ca. 89%.
- Wanneer de postcode begint met 7, 2, 5, 8 of 9, dan is de kans op vertraagde betaling volgens het model 100% voor de restgroep van ca. 89%.
- Wanneer de postcode begint met 3, 1, 4 of 6, dan is er een kans van ca. 77% op vertraagde betaling binnen de groep van 89%.

We merken op (als getoond in de hiernavolgende tabel) dat de voorspelbaarheid/verklaring van slecht betaaldegedrag zicht als getoetst in de testsample zeer goed laat voorspellen met dit model (>97% correct) en dat het correct voorspellen van het op tijd betalen hiermee lastiger blijkt (25%).

Eerder in dit onderzoek (par. 1.3.2 “foutsoorten”) werd al eens de nadruk gelegd op het voorspellen/verklaren van slecht betaaldegedrag en risico op misclassificatie. Hierbij werd aangegeven dat de kans op het onterecht “afkeuren” van kredietwaardige bedrijven los van opportuniteitsverliezen een beperkter risico vormt.

Classification

Sample	Observed	Predicted		
		,0	1,0	Percent Correct
Training	,0	5	10	33,3%
	1,0	0	58	100,0%
	Overall Percentage	6,8%	93,2%	86,3%
Test	,0	3	9	25,0%
	1,0	1	34	97,1%
	Overall Percentage	8,5%	91,5%	78,7%

Growing Method: CRT

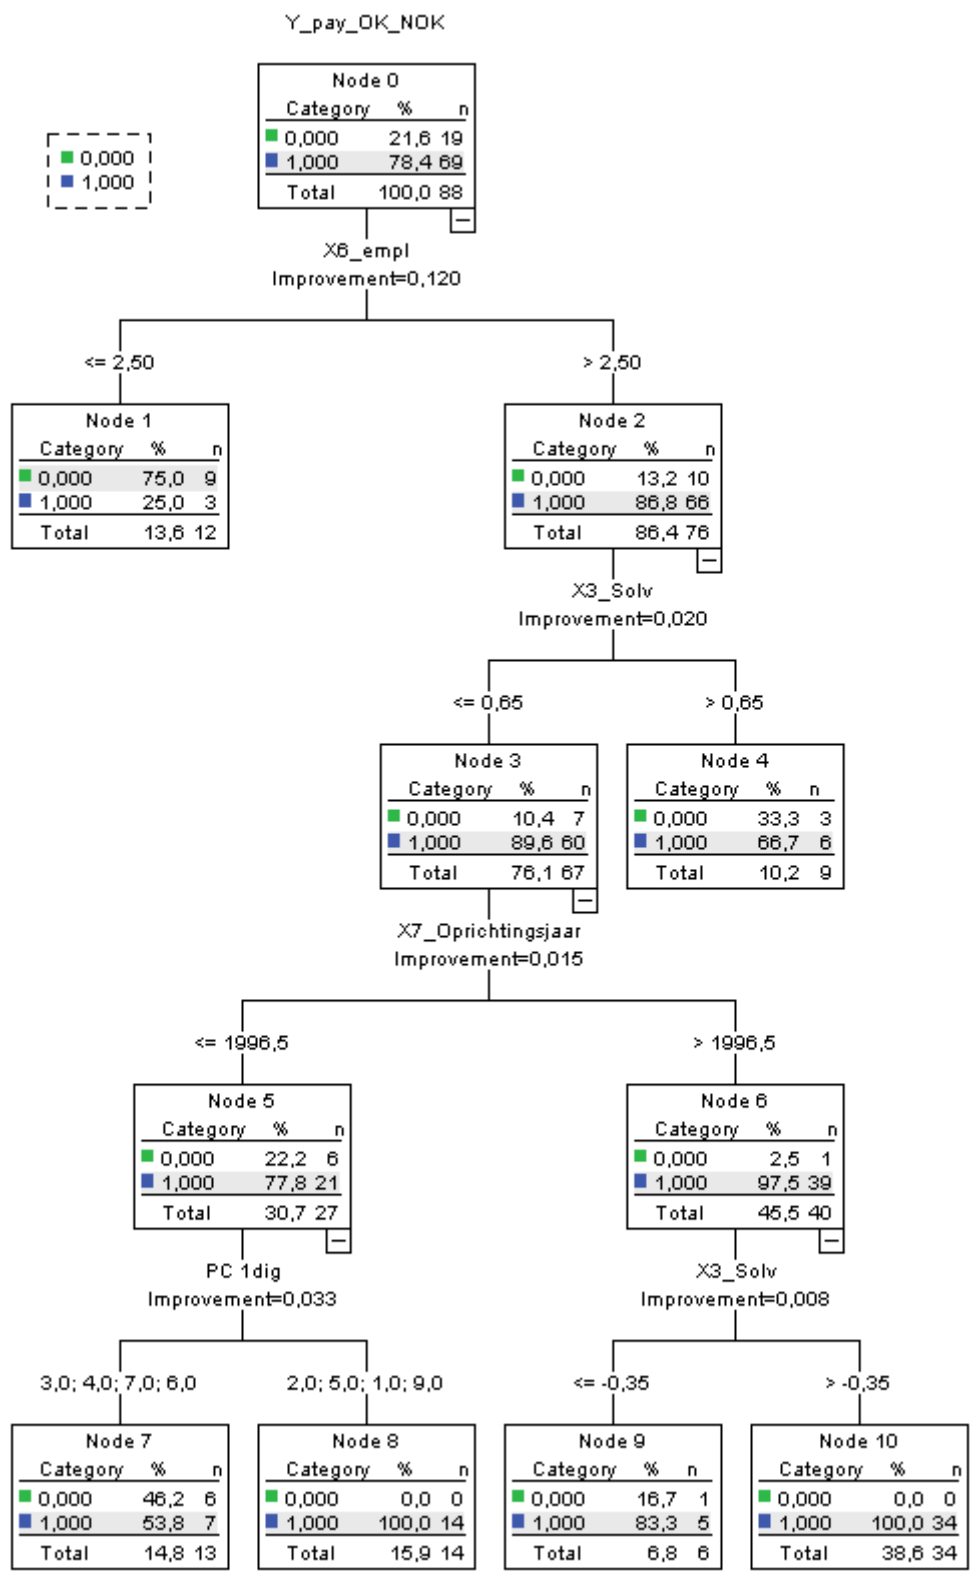
Dependent Variable: Y_pay_OK_NOK

Tabel 15 Risico op misclassificatie volgens het C(A)RT model

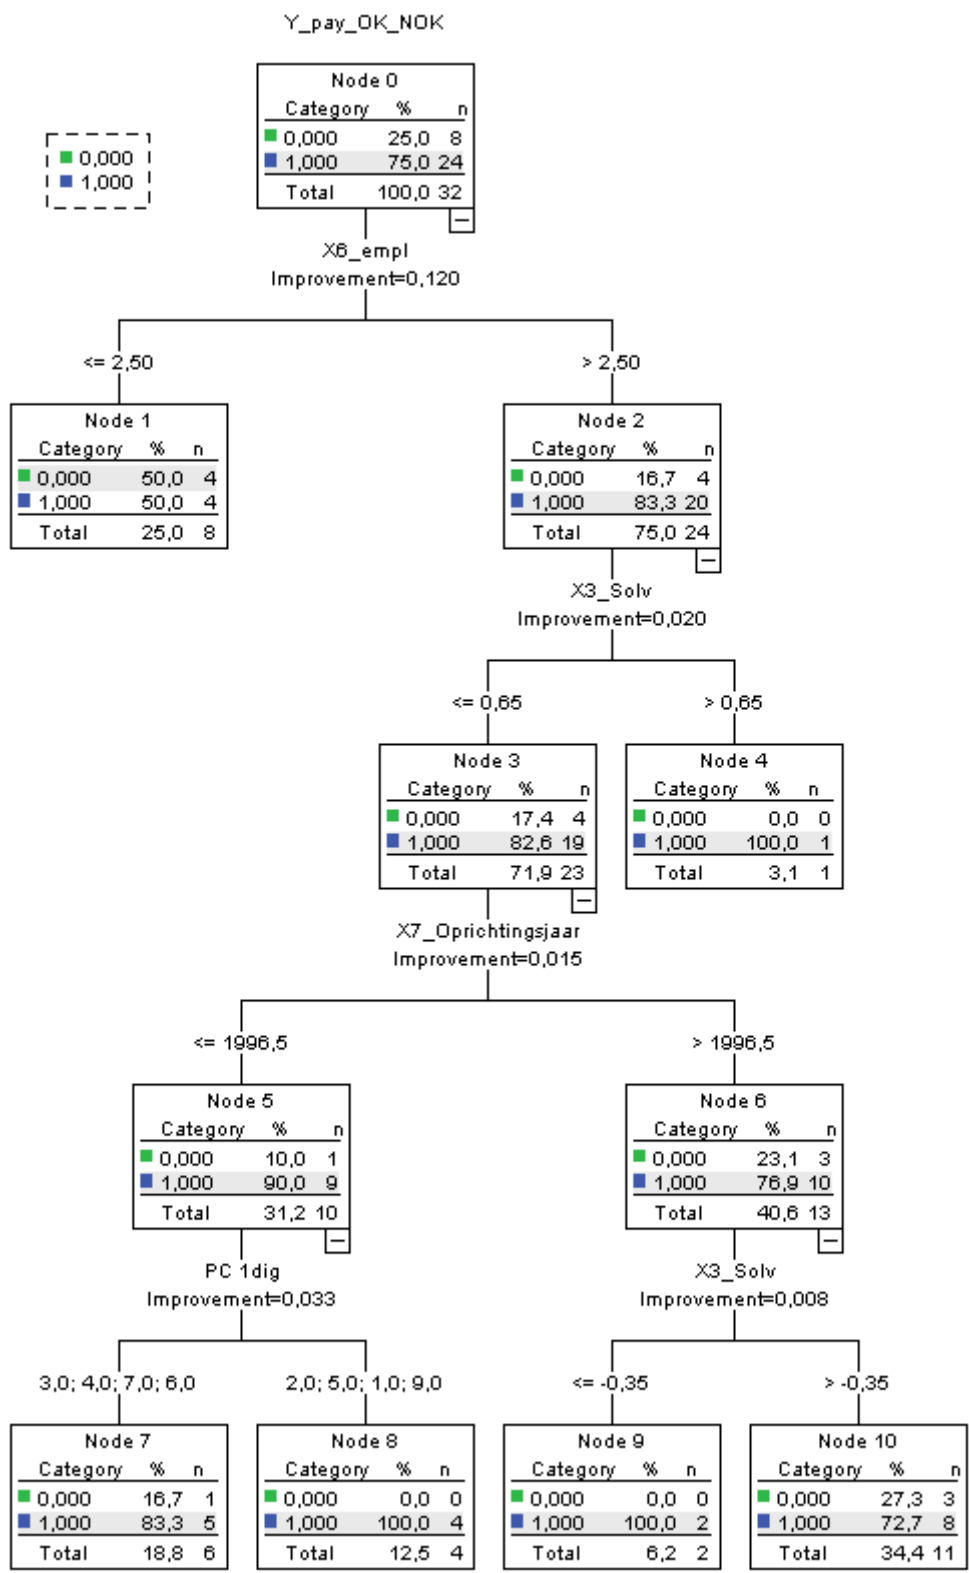
Alternatief model

Als variant op eerdergetoonde C(A)RT model vinden we een model dat zich laat lijden door solvabiliteit en oprichtingsjaar, anders dan locatie. Dit uitgebreidere model is weergegeven in de volgende figuren, waarbij:

Variabele	Definitie
Y_pay_OK_NOK	Betalingssnelheid , de snelheid waarmee facturen worden voldaan (waarbij 1= te laat en 0= binnen termijn)



Figuur 11 Alternatief (training) CRT model (OK vs. NOK)



Figuur 12 Alternatief (test) CRT model (OK vs. NOK)

Binnen het getoonde alternatief zien we de kans op meer correcte voorspelbaarheid van positief betaalgedrag beperkt toenemen tot ca. 50% van de gevallen. Dit gaat ten koste van een geringe verlaging van de correcte voorspelingskans van het te laat betalen, zie ook onderstaande tabel.

Sample	Observed	Predicted		
		,0	1,0	Percent Correct
Training	,0	9	10	47,4%
	1,0	3	66	95,7%
	Overall Percentage	13,6%	86,4%	85,2%
Test	,0	4	4	50,0%
	1,0	4	20	83,3%
	Overall Percentage	25,0%	75,0%	75,0%

Growing Method: CRT

Dependent Variable: Y_pay_OK_NOK

Tabel 16 Risico op misclassificatie volgens het alternatieve C(A)RT model

3.3.1 Deelconclusie fase 3, C(A)RT analyse op basis van een 95% betrouwbaarheid

- ✓ Bijna 80% van de bedrijven betaald volgens dit model te laat,
- ✓ wanneer een bedrijf minder dan 3 (<2,5) medewerkers heeft, dan is de kans op vertraagde betaling binnen deze groep van 80% ca. 27%
- ✓ Wanneer een bedrijf gevestigd is in Overijssel, Zuid Holland of Gelderland, dan is de kans op vertraagde betaling binnen de genoemde restgroep van 27% een 50%.
- ✓ Wanneer een bedrijf meer dan 3 (>2,5) medewerkers kent, dan is de kans op vertraagde betaling binnen de groep van ca. 80% een ca. 89%.
- ✓ Wanneer de postcode begint met 7, 2, 5, 8 of 9, dan is de kans op vertraagde betaling volgens het model 100% voor de restgroep van ca. 89%.
- ✓ Wanneer de postcode begint met 3, 1, 4 of 6, dan is er een kans van ca. 77% op vertraagde betaling binnen de groep van 89%.
- ✓ Dit model vertoont een sterk voorspellende waarde voor mogelijk vertraagde betaling (correct in >97% van de gevallen volgens de sample test toetsing).
- ✓ Dit model vertoont een zwakke correcte voorspelbaarheid voor betalingen binnen termijn.
- ✓ Binnen het getoonde (uitgebreidere) alternatieve model bieden ook solvabiliteit en oprichtingsjaar mogelijkheden om tot een alternatieve voorspelling te komen. Deze voorspelling is meer correct voor bepaling van correct betaalgedrag, maar blijft hiervoor zwak (ca. 50% kans op correcte voorspelling). De voorspelbaarheid van slecht betaalgedrag wordt in dit alternatieve model iets minder accuraat.

4 Conclusies & aanbevelingen

4.1 Samenvatting

In dit onderzoek is onderzocht welke variabelen invloed hebben op de snelheid van betalen door een 3^e onderneming (klant/afnemer). Doelstelling voor dit onderzoek is het bepalen van de meest invloedrijke variabele, welke kan worden beschouwd als sterke predictor en/of modificerende factor voor de mate van betalingsnelheid van potentiële afnemers.

Voor dit onderzoek is een dataset samengesteld om zo middels een a-selecte steekproef de doelgroep van F-gas gecertificeerde Nederlandse installatiebedrijven te analyseren. Na preparatie en modificatie/transformatie van de uiteindelijk te hanteren variabelen is dit onderzoek uitgevoerd middels een drietal statistische modellen toe te passen voor de analyse; (logistieke) regressie analyse, CHAID en C(A)RT beslisbomen. De uitkomsten van deze analyses zijn hieronder samengevat en in de latere hypothese aannames/afwijzingen naar verwezen.

4.1.1 descriptieve- & (logistieke) regressie analyse

- ✓ De relatief kleine steekproef van n=95 laat geen perfecte, significante correlatie zien tussen snelheid van betalen en de voorspellende variabelen
- ✓ Oprichtingsjaar van een onderneming heeft een significante negatieve (tegengestelde) invloed op werkkapitaal en current ratio (liquiditeit van de onderneming) → jongere bedrijven zijn minder liquide
- ✓ De algemene factoren postcode en aantal medewerkers tonen met hoge mate van waarschijnlijkheid, dat deze het eigen vermogen capteren. Respectievelijk: hogere postcode (noorden van Nederland) → lager eigen vermogen; hoger aantal medewerkers → hoger eigen vermogen
- ✓ Multivariate LR toont aan dat voorspelling met een groep van variabele mogelijk is en bij betaling OK versus NOK in 84,2% van de gevallen correcte uitkomst toont.
- ✓ Voorspellen van wanbetaling (100%) blijkt eenvoudiger dan het voorspellen van correct betaald bedrag (6,3%).

4.1.2 (exhaustive) CHAID analyse op basis van een 95% betrouwbaarheid

- ✓ We zien dat circa 77-79% van de ondernemingen uit de doelgroep van dit onderzoek te laat betalen.
- ✓ Of een onderneming op tijd of te laat betaald kan worden voorspeld aan de hand van het aantal medewerkers
- ✓ Een bedrijf met <4 medewerkers toont een ca. 45 - 50% kans op verlate betaling
- ✓ Een bedrijf met >4 medewerkers toont een 85 - 89% kans op vertraagde betaling
- ✓ In 90% van de gevallen komt deze voorspelling uit
- ✓ De kans dat een bedrijf later dan 10 dagen na vervaldatum betaald is voor de gestelde doelgroep 51%

4.1.3 C(A)RT analyse op basis van een 95% betrouwbaarheid

- ✓ Bijna 80% van de bedrijven betaald volgens dit model te laat,
- ✓ wanneer een bedrijf minder dan 3 (<2,5) medewerkers heeft, dan is de kans op vertraagde betaling binnen deze groep van 80% ca. 27%
- ✓ Wanneer een bedrijf gevestigd is in Overijssel, Zuid Holland of Gelderland, dan is de kans op vertraagde betaling binnen de genoemde restgroep van 27% een 50%.
- ✓ Wanneer een bedrijf meer dan 3 (>2,5) medewerkers kent, dan is de kans op vertraagde betaling binnen de groep van ca. 80% een ca. 89%.
- ✓ Wanneer de postcode begint met 7, 2, 5, 8 of 9, dan is de kans op vertraagde betaling volgens het model 100% voor de restgroep van ca. 89%.
- ✓ Wanneer de postcode begint met 3, 1, 4 of 6, dan is er een kans van ca. 77% op vertraagde betaling binnen de groep van 89%.
- ✓ Dit model vertoont een sterk voorspellende waarde voor mogelijk vertraagde betaling (correct in >97% van de gevallen volgens de sample test toetsing).
- ✓ Dit model vertoont een zwakke correcte voorspelbaarheid voor betalingen binnen termijn.
- ✓ Binnen het getonde (uitgebreidere) alternatieve model bieden ook solvabiliteit en oprichtingsjaar mogelijkheden om tot een alternatieve voorspelling te komen. Deze voorspelling is meer correct voor bepaling van correct betaalgedrag, maar blijft hiervoor zwak (ca. 50% kans op correcte voorspelling). De voorspelbaarheid van slecht betaalgedrag word in dit alternatieve model iets minder accuraat.

In paragraaf 2.1.2 zijn de ook hieronder volgende hypothesen benoemd. Deze hypothesen zijn getoetst middels analyse, waarvan de resultaten in hoofdstuk 3 van dit rapport zijn opgenomen, en hiermee de creatie van verschillende statistische modellen, welke middels gebruikmaking van relevante variabelen een hoge voorspellende waarde tonen met betrekking tot het betaalgedrag van een onderneming.

In dit hoofdstuk zullen de hypothesen worden afgewezen of aangenomen op basis van voorgaande onderzoek.

4.2 Hypotheses, conclusies & aanbevelingen

“De te verwachten betalingssnelheid van een onderneming laat zich meest significant voorspellen, lees beïnvloeden, door één of een combinatie van de in hypothese 1-7 genoemde variabelen.”

Dit was de **8^e (slot)hypothese** van dit onderzoek, en is aangenomen. Hiermee kan een positief antwoord worden gegeven op realisatie van de onderzoeksdoelstelling.

Er zijn binnen de (logistieke) regressie analyse (par 3.1) significante correlaties waargenomen tussen de variabelen onderling, echter niet significant met betrekking tot het betaalgedrag. Wel kon er middels een multivariate LR een model met voorspellende waarde worden gevormd met behulp van de geselecteerde/beschikbare variabelen.

In de latere “beslisboom modellen” (par 3.2 – 3.3) zijn duidelijk aanwijzingen gevonden die erop duiden dat de invloed van de variabele aantal medewerkers en locatie van de onderneming substantiële bijdrage leveren aan de voorspelbaarheid van het wel of niet op tijd betalen.

We merken hierbij op dat met name het aantal medewerkers van belang is voor een eerste “risico schifting”.

Met het oog op locatie zijn er vermoedens dat de plaatselijke economieën en bedrijvigheid mogelijk aanleiding geven voor de significante constatering.

Hypothese 1-4

- 1 “Een hoge current-ratio voorspelt een hoge betaalsnelheid.”
→ afgewezen
- 2 “Een hoog werkkapitaal voorspelt een hoge betaalsnelheid”
→ afgewezen
- 3 “Een hoge solvabiliteitsratio voorspelt een hoge betaalsnelheid”
→ afgewezen
- 4 “Een hoog eigen vermogen voorspelt een hoge betaalsnelheid”
→ afgewezen

De toelichting hierbij is als volgt:

Er zijn binnen de (logistieke) regressie analyse (par 3.1) wel geringe correlaties waargenomen, echter niet significant. Ook zijn in de latere “beslisboom modellen” (par. 3.2 - 3.3) geen aanwijzingen gezien die erop duiden dat de invloed van deze variabele substantieel is.

Hypothese 5.

“De locatie van een bedrijf is bepalend voor het betaalgedrag.”

Deze hypothese is in de context van dit onderzoek aangenomen.

Er zijn binnen de (logistieke) regressie analyse (par 3.1) geringe correlaties waargenomen, echter niet significant. Wel zijn er in de latere “beslisboom modellen” (par 3.2 – 3.3) aanwijzingen gevonden die erop duiden dat de invloed van deze variabele substantieel is.

We signaleerden specifieke gebieden welke een relatie blijken te hebben met het betaalgedrag. Zo zien we bijvoorbeeld een slechter betaalgedrag in het Noorden van Nederland. Het vermoeden bestaat dat de lokale economische verschillen gerelateerd kunnen worden aan het betaalgedrag. Zo refereren we bijvoorbeeld naar de beperktere bedrijvigheid volgens KvK en ook onderwerpen als een Zuiderzee lijn. Later in de reflectie op dit onderzoek word hier verder op ingegaan.

Hypothese 6.

“Een bedrijf met een hoog aantal werknemers betaalt sneller.”

Deze hypothese is in de context van dit onderzoek afgewezen.

Er zijn binnen de (logistieke) regressie analyse (par 3.1) geringe correlaties waargenomen, echter niet significant. Wel zijn er in de latere “beslisboom modellen” (par 3.2 -3.3) aanwijzingen gevonden die erop duiden dat de invloed van deze variabele substantieel is. Hieruit blijkt echter het tegengestelde; bedrijven met een hoog aantal medewerkers tonen een grotere kans op te late betaling.

Hypothese 7.

“Bedrijven die langer bestaan betalen sneller.”

Deze hypothese is in de context van dit onderzoek afgewezen.

Er zijn binnen de (logistieke) regressie analyse (par 3.1) geringe correlaties waargenomen, echter niet significant. Wel zijn in de latere “beslisboom modellen” (par 3.2 - 3.3) aanwijzingen gevonden die erop duiden dat de invloed van deze variabele aanwezig is, echter is de relatie en richting onvoldoende duidelijk gebleken. Zo blijkt ook uit de logistieke regressie analyse dat jongere bedrijven minder liquide zijn.

Hypothese 8.

“De te verwachten betalingssnelheid van een onderneming laat zich meest significant voorspellen, lees beïnvloeden, door één of een combinatie van de in hypothese 1-7 genoemde variabelen.”

Deze hypothese is in de context van dit onderzoek aangenomen.

Er zijn binnen de (logistische) regressie analyse (par 3.1) significante correlaties waargenomen tussen de variabelen onderling, echter niet significant met betrekking tot het betaalgedrag.

In de latere “beslisboom modellen” (par 3.2 – 3.3) zijn duidelijk aanwijzingen gevonden die erop duiden dat de invloed van de variabele aantal medewerkers en locatie van de onderneming substantiële bijdrage leveren aan de voorspelbaarheid van het wel of niet op tijd betalen.

We merken hierbij op dat met name het aantal medewerkers van belang is voor een eerste “risico schifting”.

Aanbevelingen

We zien dat de gebruikte methodiek uit dit onderzoek kan leiden tot een model / modellen dat/die de kans op ontijdige betaling voorspellen. Het is voor een volgend onderzoek aan te bevelen de te hanteren dataset verder uit te breiden met meer ondernemingen. Op deze wijze kan er gebruik gemaakt worden van een grotere trainingsgroep, een grotere testgroep en kan mogelijk ook tot modellen worden gekomen welke de kans op correct betaalgedrag beter weergeven. Het is hierbij tevens mogelijk interessant om ook stil te staan bij endogeniteit en identificatie van mogelijke causale verbanden, naast de correlaties. Bijvoorbeeld: “Bestaat een bedrijf langer, doordat het op tijd betaald? Betaald een bedrijf op tijd, omdat het langer bestaat? Etc...”

We zien dat enkele bedrijven buiten scope blijven in dit onderzoek, omdat van hen geen financiële gegevens beschikbaar zijn. Het verdient dan ook de aanbeveling om in een volgend onderzoek ook de informatie van deze nu buiten scope gehouden ondernemingen mee in beschouwing te nemen, bijvoorbeeld middels interviews.

Het is interessant te zien dat de locatie en het aantal medewerkers een sterke invloed uitoefenen binnen de modellen. Met betrekking tot de locatie verdient het de aanbeveling om het onderzoek te herhalen met een selectie-/representatieve steekproef, waarbij er nadrukkelijk wordt gelet op de afspiegeling van de regionale concentraties binnen de steekproef versus de populatie/doelgroep (“sample BIAS re-testing”).

Het verdient de aanbeveling te onderzoeken wat nu de sectorinvloed is op het betalingsgedrag binnen deze doelgroep, evenals of hier conjunctuur gevoeligheden zijn te vinden.

5 Methodologische reflectie

Tijdens de methodologische reflectie word stilgestaan bij de punten/onderwerpen welke tijdens dit onderzoek aanleiding gaven voor verdere evaluatie/reflectie. Deze onderwerpen zijn hieronder behandeld:

- De centrale onderzoeksvraag, en correlatie → De onderzoeksvraag luidde: “Welke variabele heeft, of groep van variabele hebben de sterkste, significante invloed op kredietrisico onder afnemers, waarbij het risico word uitgedrukt in de snelheid van betaling?” Tijdens het onderzoek dat hierna plaatsvond is er met name stilgestaan bij het zoeken naar en vinden van correlaties, zonder identificatie. Er is slechts beperkt uitgebreid over causale verbanden. Hiermee is mogelijk te snel voorbijgegaan aan endogeniteitsvraagstukken. Het zou mogelijk interessant zijn geweest vaker/langer stil te staan bij vragen als: “Wordt er op tijd betaald, omdat variabele X hoog danwel laag is? Of, is variabele X hoog/laag omdat er op tijd word betaald?”
- Power → de kracht van de analyse voor LR is beperkt gebleken. Er was niet genoeg data beschikbaar om een effect van omvang statistisch significant te kunnen constateren.
- Postcode zo bepalend? → heeft dit te maken met de regionale attitude? Demografie? Of is hier sprake van een bias in de data? Mogelijk zou er een analyse kunnen worden gedaan voordat er werd gekozen voor een a-selecte steekproef. Op deze wijze zou een selecte/representatieve steekproef de voorkeur kunnen hebben gekregen en enige twijfel omtrent representativiteit van de steekproef kunnen wegnemen. Om op andere wijze, na onderzoek, toch de representativiteit op gebied van locatie te kunnen relativeren is onderstaande tabel opgenomen. Hierin zien we dat de steekproef versus de populatie van de doelgroep volgens de KvK in de meest rechtse kolom word getoond. We zien hierbij dat een selecte steekproef mogelijk beter tot zijn recht had gekomen in termen van representativiteit. Door betere afspiegeling van de regionale concentraties binnen de steekproef versus de populatie/doelgroep (“sample BIAS re-testing”).

1-cijferige postcode	% volgens KvK	% in steekproef	steekproef vs. KvK
1	14%	10%	70%
2	16%	18%	112%
3	17%	13%	77%
4	9%	12%	138%
5	14%	18%	128%
6	10%	11%	111%
7	9%	11%	120%
8	6%	3%	52%
9	5%	4%	78%

Provincie	% volgens KvK	% in steekproef	steekproef vs. KvK
Groningen	3%	1%	38%
Friesland	3%	3%	89%
Drenthe	3%	3%	107%
Overijssel	6%	7%	114%
Flevoland	2%	1%	51%
Gelderland	12%	13%	106%
Utrecht	8%	9%	111%
Noord-Holland	16%	8%	51%
Zuid-Holland	22%	23%	106%
Zeeland	2%	3%	126%
Noord-Brabant	17%	21%	121%
Limburg	6%	8%	137%

Tabel 17 Representativiteit van de steekproef op basis van locatie

- Postcode en medewerker bijna significant? → we zien dat bij een betrouwbaarheid van 95% deze resultaten geen significante relatie met het eigen vermogen tonen. We zien ook andere “aanwijzingen” zonder dat significantie kan worden aangetoond. Een grotere dataset had mogelijk meer significante resultaten naar boven kunnen brengen, met tevens kleinere afwijkingen tussen training en test simulaties voor getoonde modellen.
- Benchmarking DB? → Wanneer er nadrukkelijk wordt gezocht achter een model, dan is het mogelijk interessant om deze naast andere kredietbeoordelingen te zetten om zo de representativiteit en waarde van het model te evalueren/beoordelen.
- Er zijn niet altijd financiële cijfers bekend en ook niet voor alle rechtsvormen? → We zien dat enkele bedrijven buiten scope blijven in dit onderzoek, omdat van hen geen financiële gegevens beschikbaar zijn. Het verdient dan ook de aanbeveling om in een volgend onderzoek ook de informatie van deze nu buiten scope gehouden ondernemingen mee in beschouwing te nemen, bijvoorbeeld middels interviews.

- Het verdient de aanbeveling te onderzoeken wat nu de sectorinvloed is op het betalingsgedrag binnen de onderzochte doelgroep, evenals of hier conjunctuur gevoeligheden zijn te vinden. Tijdens dit onderzoek is namelijk in beperkte mate gekeken naar de evolutie van bedrijven over de tijd. Een gevolg van dit, Omitted variable bias, kan zorgen voor onder / over estimatie van een effect veroorzaakt door een variabele → wat is over het hoofd gezien? → “non-stationary effects”, waarbij wordt verondersteld dat “het effect” ergens sterk is, maar niet elders, kan bijvoorbeeld een gevolg zijn van mogelijke interactie vanuit effecten welke nu, als gevolg van voorgaande, over het hoofd zijn gezien.

6 Bibliografie

- Decision_tree_learning*. (2013, mei 20). Opgeroepen op mei 20, 2013, van Wikipedia: http://en.wikipedia.org/wiki/Decision_tree_learning
- Kamer van Koophandel*. (2013, mei 20). Opgeroepen op mei 20, 2013, van KvK: <https://www.kvk.nl/handelsregister/zoekenframeset.asp?zk=0&url=https://server.db.kvk.nl/ia>
- Omitted-variable_bias*. (2013, mei 20). Opgeroepen op mei 20, 2013, van Wikipedia: http://en.wikipedia.org/wiki/Omitted-variable_bias
- Baesens, B., Van Gestel, T., Viaene, S., Stepanova, M., Suykens, J., & Vanthienen, J. (2003). Benchmarking State-of-the-Art Classification Algorithms for Credit Scoring. *The Journal of the Operational Research Society*, Vol. 54, nr 6, 627-635.
- Banasik, J., & Crook, J. (2005). Credit Scoring, Augmentation and Lean Models. *The Journal of the Operational Research Society*, Vol. 56, nr 9, 1072-1081.
- Copas, J. (1999). Statistical Modelling for Risk Assessment. *Risk Management*, vol. 1, nr 1, 35-49.
- Dietsch, M., & Petey, J. (2004). Should SME exposures be treated as retail or corporate exposures? A comparative analysis of default probabilities and asset correlations in French and German SMEs. *Journal of Banking & Finance*, nr 28, 773-788.
- Hand, D., & Henley, W. (1997). Statistical Classification Methods in Consumer Credit Scoring: A Review. *Journal of the Royal Statistical Society. Series A*, Vol. 160, nr 3, 523-541.
- Liu, Y., & Schumann, M. (2005). Data Mining Feature Selection for Credit Scoring Models. *The Journal of the Operational Research Society*, Vol 56, nr 9, 1099-1108.
- Mester, L. J. (1997). What's the Point of Credit Scoring? *Business Review*, 5;7;11;14.
- Oliver, R., & Wells, E. (2001). Efficient Frontier Cutoff Policies in Credit Portfolios. *The Journal of the Operational Research Society*, Vol. 52, nr 9, Special Issue: Credit Scoring and Data Mining, 1025-1033.
- Pike, R., & Sang Cheng, N. (2001). Credit Management: An Examination of Policy Choices, Practices and Late Payment in UK Companies. *Journal of Business Finance & Accounting*, nr 28(7) & (8), 1014-1039.
- Reichert, A. K., Cho, C.-C., & Wagner, G. M. (1983). An Examination of the Conceptual Issues Involved in Developing Credit-Scoring Models. *Journal of Business & Economic Statistics*, Vol. 1, nr 2, 101-114.
- Tian-Shyug, L., Chih-Chou, C., Chi-Jie, L., & I-Fei, C. (2002). Credit scoring using the hybrid neural discriminant technique. *Expert Systems with Applications*, nr 23, 246-252.
- Tian-Shyung, L., Chih-Chou, C., Yu-Chao, C., & Chi-Jie, L. (2006). Mining the customer credit using classification and regression tree and multivariate adaptive regression splines. *Computational Statistics & Data Analysis*, nr 50, 1114-1127.
- Tranmer, M., & Elliot, M. (2013, juni 9). *Binary Logistic Regression*. Opgeroepen op juni 9, 2013, van <http://www.ccsr.ac.uk>: <http://www.ccsr.ac.uk/publications/teaching/blr.pdf>

- Tsai, H. T., Thomas, L. C., & Yeh, H. C. (2005). An Economic Model for Credit Assessment Problems Using Screening Approaches. *The Journal of the Operational Research Society*, Vol. 56, nr 7, 836-843.
- Wuensch, K. L. (2013, juni 9). *Binary Logistic Regression with PASW/SPSS*. Opgeroepen op juni 9, 2013, van <http://core.ecu.edu/http://core.ecu.edu/psyc/wuenschk/MV/Multreg/Logistic-SPSS.pdf>
- Yap, B. W., Ong, S. H., & Husain, N. H. (2011). Using data mining to improve assessment of credit worthiness via credit scoring models. *Expert Systems with Applications*, nr 38, 13275-13283.