Nederlands Instituut Publieke Veiligheid

DATAPRO112

Naar datagedreven werken met incidentdata



Veiligheidsregio Gelderland-Zuid

VEILIGHEIDS REGIO TWENTE

VEILIGHEIDSREGIO IJsselland

Veiligheids- en Gezondheidsregio Gelderland-Midden

veiligheidsregio Noord- en Oost-Gelderland

VEILIGHEIDSREGIO Midden- en West-Brabant

Veiligheidsregio Amsterdam-Amstelland

Nederlandse Academie voor
Crisisbeheersing en Brandweerzorg
Postbus 7010
6801 HA Arnhem
Kemperbergerweg 783, Arnhem
www.nipv.nl
info@nipv.nl
026 355 24 00

Colofon

© Nederlands Instituut Publieke Veiligheid (NIPV), 2026

Auteurs	H. Weda, L. de Bruijn, A. de Boer, S. Geurts, R. Groot Beumer, R. Hakvoort, R. Holtman, V. Jansen, E. Klein Goldewijk, G. Legemaate, M. de Man, S. McEwen-Verver, M. Meijerink, N. van Oorschot, V. Oosterveen, J. Oude Voshaar, S. Troost, P. Visscher, J. Wessels, J. van Balen-de Greef, A. Matser
Contactpersoon	L. de Bruijn
Subsidiegever	Ministerie van Binnenlandse Zaken en Koninkrijksrelaties, Innovatie Budget Digitale Overheid
Contactpersoon	L. Kramer
Datum	21 september 2026
Foto cover	Shutterstock

Wij hechten veel belang aan kennisdeling. Delen uit deze publicatie mogen dan ook worden overgenomen op voorwaarde van bronvermelding.

Bij het opstellen van dit rapport is AI ingezet voor aanscherping van teksten. De auteurs zijn verantwoordelijk voor de inhoud, analyses, interpretaties en conclusies van het rapport.

Het Nederlands Instituut Publieke Veiligheid is bij wet vastgelegd onder de naam Instituut Fysieke Veiligheid.

Voorwoord

Veiligheidsregio's (VR's) worden geconfronteerd met toenemende complexiteit van incidenten en crises. Om de toekomstbestendigheid en flexibiliteit van de VR's te vergroten en beter voorbereid te zijn op incidenten en crises nu en in de toekomst wordt onder andere ingezet op informatiegestuurd werken en bovenregionale samenwerking. Hiervoor is het nodig om meer data en informatie met elkaar te delen en dan is het ook belangrijk dat er consensus is over de betekenis van deze data en informatie. Ook zou het mooi zijn als we meer gebruik kunnen maken van data-science technieken om zo processen te optimaliseren en de effectiviteit van incidentbestrijding te verhogen.

Toch is er nu geen gezamenlijk informatieproces en wordt slechts een deel van de data uit het 112-incidentafhandelingsproces landelijk verwerkt. Er is geen landelijk inzicht in geverifieerde incidentmeldingen. Mogelijkheden voor ontwikkeling en implementatie van bovenregionaal en landelijk toepasbare modellen is beperkt. En juist de landelijke dataverwerking, analyse en modelontwikkeling worden steeds belangrijker, bijvoorbeeld om snel en accuraat regio-overstijgend te kunnen optreden bij grote incidenten en crises, wat de effectiviteit van incidentbestrijding verhoogd.

Dit was voor de deelnemende VR's en het NIPV de aanleiding om DATAPRO112 te starten. Dit project is een samenwerking tussen Veiligheidsregio Midden- en West-Brabant (VRMWB), Veiligheidsregio Noord- en Oost-Gelderland (VNOG), Veiligheidsregio Gelderland Midden (VGGM), Veiligheidsregio Gelderland Zuid (VRGZ), Veiligheidsregio IJsselland (VR IJsselland), Veiligheidsregio Twente (VRT), Veiligheidsregio Amsterdam-Amstelland (VRAA) en het Nederlands Instituut Publieke Veiligheid (NIPV).

We kijken terug op een mooi en leerzaam jaar, waarin door alle betrokken partijen enthousiast is samengewerkt en veel werk is verzet. Het doel van DATAPRO112 was tweeledig. Enerzijds was het project bedoeld om data-analisten en data scientists uit de regio's te verbinden en samen te werken aan data-analytische vraagstukken. Anderzijds had het een inhoudelijk doel, namelijk meer inzicht krijgen in de mogelijkheden van de data die verzameld worden over het 112 incidentafhandelingsproces, na te gaan in hoeverre de data geschikt zijn om data science toepassingen op te ontwikkelen en aanbevelingen te doen voor verbetering en uniformering.

In dit rapport worden verschillende deelonderzoeken die zijn uitgevoerd beschreven. Naast de conclusies die getrokken konden worden op basis van deze onderzoeken, zijn er overkoepelende conclusies, aanbevelingen en vervolgstappen geformuleerd.

Wij danken de data-analisten en data scientists die met enthousiasme dit project tot een succes hebben gemaakt.

De stuurgroep,
Jolande van Balen, Amy Matser, Jaap van 't Riet, Sandra Mc Ewan, Guido Legemaate, Paul Visscher, Arend de Boer, Marco de Man, Remco Groot Beumer

Inhoud

	Voorwoord	**3**
	Inleiding	**5**
1	**Opzet en uitvoering van het project**	**8**
1.1	Governancestructuur	8
1.2	Uitvoering van het project	8
2	**Data-uitwisseling**	**11**
2.1	Data uit het Geïntegreerd Meldkamer Systeem (GMS)	11
2.2	Aanvullende regionale data	12
2.3	Data van het Centraal Bureau voor de Statistiek (CBS)	17
2.4	Gebruikte software voor data laden en opschonen	17
2.5	Conclusies over huidige data-uitwisseling	18
3	**Data-analyse**	**19**
3.1	Algemene kenmerken van de data	20
3.2	Kladblokkenmerken	32
3.3	Karakteristieken	36
3.4	Uniformiteit van karakteristiekgebruik tussen VR's	39
3.5	Incidentverificatie	44
3.6	Procesanalyse	48
3.7	Slachtoffers bij woningbranden	51
3.8	Classificeren en clusteren kladbloktekst	58
3.9	Trendanalyse in kladblokregels	67
3.10	Opschalingvoorspelling	81
4	**Conclusies**	**85**
4.1	Vervolgonderzoek	87
4.2	Aanbevelingen	88
	Literatuur	**90**
	Bijlage 1 – Interview	**93**

Inleiding

De veiligheidsregio's (VR's) zijn verantwoordelijk voor de brandweerzorg en crisisbeheersing in Nederland. Zij worden geconfronteerd met een grote diversiteit aan incidenten die in complexiteit toenemen (NIPV, 2022). Zo brengt bijvoorbeeld de energietransitie nieuwe typen incidenten met zich mee, zoals accubranden. En als gevolg van klimaatverandering neemt de kans op en intensiteit van natuurbranden toe. Om de toekomstbestendigheid en flexibiliteit van de brandweerzorg te vergroten en beter voorbereid te zijn op incidenten en crises nu en in de toekomst, wordt ingezet op bovenregionale samenwerking en is goede informatieoverdracht belangrijk (Brandweer Nederland, 2026).

Om informatiegestuurd te kunnen werken, zijn goede en eenduidige data nodig. Maar waarom is dat zo? Goede data vormen de basis voor inzicht, besluitvorming, communicatie en samenwerking. Door het verzamelen, combineren en analyseren van data kunnen VR's risico's beter in beeld brengen, trends herkennen en scenario's voorspellen. Dit ondersteunt zowel de voorbereiding als de operationele inzet, bijvoorbeeld bij het positioneren van middelen, het plannen van beschikbaarheid, het delen van een actueel beeld tussen regio's tijdens incidentbestrijding en het evalueren van incidenten achteraf. Bovendien maken gestandaardiseerde en betrouwbare data het mogelijk om informatie bovenregionaal te delen, vergelijken en te benutten, waardoor kennis sneller kan worden gedeeld en de VR's als geheel wendbaarder en effectiever kunnen optreden.

Wanneer er een incident plaatsvindt, worden hulpdiensten, waaronder de brandweer, meestal ingeschakeld door een telefonische melding door een burger via 112. Het gesprek komt binnen op een van de tien meldkamers. De meldkamercentralist stelt gerichte vragen over de aard en locatie van het incident en rapporteert de verkregen gegevens in het Geïntegreerd Meldkamer Systeem (GMS). De centralist alarmeert ook de specifieke brandweereenheden van de VR's en voorziet deze van de beschikbare informatie uit de melding. Tijdens de inzet blijft de meldkamer het aanspreekpunt voor extra informatie en coördinatie, bijvoorbeeld wanneer aanvullende inzet of ondersteuning van andere hulpdiensten nodig is. Het GMS is hierin een cruciaal operationeel systeem. De primaire functie van het GMS is het faciliteren van de communicatie tussen meldkamer en hulpdienst, zodat gemelde incidenten tijdig en adequaat kunnen worden bestreden.

Het GMS is niet primair bedoeld voor rapportage en evaluatie achteraf. Het wordt daarom bijvoorbeeld na een incident zelden bijgewerkt of aangevuld met additionele data over het incident en de bestrijding. Hierdoor kan het voorkomen dat de classificatie van de incidentmelding die tijdens het telefoongesprek wordt gegeven door de centralist niet volledig overeenkomt met de situatie die de bevelvoerder op locatie heeft aangetroffen, of dat het incident en bestrijding er anders hebben uitgezien dan op basis van GMS kan worden verondersteld. Daarnaast is er geen gezamenlijk informatieproces en zijn er slechts beperkte afspraken over datastandaardisatie, waardoor er in de betekenis van data verschillen zijn tussen regio's.
Naast het GMS worden in de diverse VR's vaak additionele aspecten van de incidenten vastgelegd in eigen systemen om ze later te kunnen evalueren en/of analyseren. Of en hoe

dit gebeurt, kan per VR verschillen. Tot op heden vindt er geen landelijke uitwisseling van deze data plaats en is het inzicht in elkaars (meta-)data zeer beperkt. Dat is jammer, want deze gegevens kunnen een completer beeld geven van incidenten en de bestrijding, bieden kansen om te leren en om de incidentbestrijding te ondersteunen met datatoepassingen.

Om informatiegestuurd werken mogelijk te maken, optimaal gebruik te kunnen maken van datatoepassingen en de bovenregionale samenwerking te ondersteunen, is een kwaliteitsverbetering van de datastroom belangrijk. Daarom hebben de VR's Midden- en West-Brabant, Noord- en Oost-Gelderland, Gelderland-Zuid, IJsselland, Twente, Amsterdam-Amstelland, Veiligheids- en Gezondheidsregio Gelderland-Midden en het NIPV de handen ineengeslagen in het DATAPRO112-project. Deze zeven VR's zijn verantwoordelijk voor het 112-incidentafhandelingsproces van ongeveer 20 % van de 140.000 jaarlijkse 112-meldingen van de brandweer in Nederland. Het project bouwt voort op data-analyses van de individuele VR's en de *Kerncijfers Brandweer* (NIPV, z.d.). Deze rapportages zijn met name gebaseerd op de data van incidentmeldingen uit GMS.

Doelstelling

Met het DATAPRO112-project willen wij een handreiking bieden om datastandaardisatie te stimuleren, waarmee de integrale dienstverlening aan burgers in de deelnemende VR's kan worden bevorderd. Hiertoe zijn de volgende doelen geformuleerd:

1. Het samenbrengen van de beschikbare data die worden verzameld over incidenten en de bestrijding daarvan uit GMS en uit aanvullende systemen van de VR's, indien beschikbaar.
2. Het analyseren van de beschikbare data over het 112-incidentafhandelingsproces.
3. Het onderzoeken van data-science-toepassingen die besluitvorming tijdens het 112-incidentafhandelingsproces kunnen ondersteunen, om zo een eventuele meerwaarde van verbetering van de datakwaliteit te tonen.
4. Het formuleren van concrete aanbevelingen en vervolgstappen voor het verbeteren van de datakwaliteit en landelijke datastandaardisatie, onder andere om implementatie van de optimalisatiemodellen mogelijk te maken.

Leeswijzer

In Hoofdstuk 1 worden de opzet en uitvoering van het project verder toegelicht. Daarbij wordt beschreven hoe het project is onderverdeeld in verschillende werkpakketten. In Hoofdstuk 2 wordt beschreven welke data er in dit project zijn gebruikt. We beschrijven de manier waarop data momenteel per VR worden uitgewisseld tussen hulpverleners vóór, tijdens en na een incident. Hoofdstuk 3 bevat de resultaten van de verschillende onderzoeksvragen, waarbij elke vraagstelling in een aparte paragraaf wordt behandeld met een korte inleiding, de toegepaste methode, resultaten en een conclusie. Dit hoofdstuk is onderverdeeld in de volgende thema's: Incidenten en algemene regiokenmerken (3.1), kladblokkenmerken (3.2), karakteristieken (3.3 en 3.4), incidentverificatie (3.5), procesanalyse (3.6), slachtoffers bij woningbranden (3.7), clusteren van kladbloktekst (3.8), trendanalyse in kladblokregels (3.9) en opschalingvoorspelling (3.10). Het rapport sluit af met Hoofdstuk 4, waarin de algemene conclusies, discussiepunten, aanbevelingen en mogelijkheden voor vervolgonderzoek worden besproken.

De opbouw van dit rapport sluit aan bij hoe er in dit project is gewerkt. De data-analisten en data scientists die betrokken waren hebben in kleine teams elk een onderzoeksvraag geformuleerd en uitgewerkt, waarbij verschillende thema's aan de orde zijn gekomen. Meer detail hierover wordt gegeven in het volgende hoofdstuk.

1 Opzet en uitvoering van het project

1.1 Governancestructuur

De project governance bestond uit een stuurgroep, een projectleider, een inhoudelijk projecteider en werkgroepen. De stuurgroep, samengesteld uit ten minste één vertegenwoordiger van iedere consortiumpartner, was verantwoordelijk voor de strategische besluitvorming en projectfinanciën. De projectleider was verantwoordelijk voor de projectmatige aansturing van het project. Daarnaast onderhield de projectleider het contact met de subsidiegever en stakeholders, en vervulde daarbij een verbindende en coördinerende rol. De inhoudelijk projectleider was verantwoordelijk voor de inhoudelijke voortgang van de werkgroepen.

De werkgroepen waren verantwoordelijk voor de uitvoering van de verschillende werkpakketten die hieronder beschreven worden. De werkgroepen kwamen naast bijeenkomsten in groepsverband vier keer plenair samen om de plannen, voortgang, resultaten en vervolgstappen af te stemmen en kennis te delen. Zij hadden via de Sharepointomgeving van het NIPV toegang tot de data en deelden Python code met elkaar via Gitlab [1]. Resultaten en rapportage werden gedeeld via de Sharepointomgeving van VRMWB die het regievoerderschap van het project had.

1.2 Uitvoering van het project

Het project was georganiseerd in vijf samenhangende werkpakketten. Hieronder wordt een korte beschrijving van elk werkpakket gegeven.

1.2.1 Werkpakket 1 – Projectmanagement

Ter voorbereiding op de uitvoering van het project zijn de samenwerkingsovereenkomst en de benodigde data-uitwisselingsovereenkomsten opgesteld en afgesloten. Gedurende het project was de projectleider verantwoordelijk voor de dagelijkse coördinatie en voortgangsbewaking. De stuurgroep kwam iedere zes weken digitaal bijeen om de voortgang te bespreken, strategische keuzes te maken en eventuele knelpunten te adresseren. Daarnaast waren er drie live bijeenkomsten. Conceptrapportages en tussenresultaten uit de verschillende werkgroepen werden voorgelegd aan de stuurgroep voor inhoudelijke beoordeling, waarna deze na verwerking van de ontvangen feedback definitief werden gemaakt.

1.2.2 Werkpakket 2 – Data-uitwisseling

Binnen dit werkpakket is een inventarisatie uitgevoerd om te achterhalen welke gegevens over het 112-incidentafhandelingsproces de deelnemende VR's naast de data uit het GMS

[1] Toegankelijk voor NIPV en VR's.

verzamelden. Hiervoor zijn metadata opgevraagd en geanalyseerd. Aanvullend zijn er semigestructureerde interviews uitgevoerd met data-experts van de betrokken organisaties. Deze gesprekken gaven inzicht in de wijze van registratie van gegevens in regionale datasystemen (anders dan het GMS) en de beschikbare variabelen in deze bronnen.

Op basis van de inventarisatie is een data-uitwisselingsplan opgesteld waarin afspraken zijn vastgelegd over de aan te leveren gegevens en de wijze van gegevensuitwisseling. Dit plan was onderdeel van de samenwerkingsovereenkomst. Na ondertekening van de overeenkomst zijn de datasets door de deelnemende VR's beschikbaar gesteld. De gegevens zijn opgeslagen in de beveiligde NIPV-omgeving, waar zij toegankelijk werden gemaakt voor de onderzoekers en werkgroepen die betrokken waren bij de verdere analyses.

1.2.3 Werkpakket 3 & 4 – Data-analyse

Door vertraging bij het afronden van de samenwerkingsovereenkomst is besloten de werkzaamheden binnen werkpakket 3 en werkpakket 4 parallel uit te voeren.
Tijdens een gezamenlijke startbijeenkomst zijn, op basis van een eerste verkennende analyse van de beschikbare gegevens, relevante onderzoeksvragen geformuleerd. Deze onderzoeksvragen zijn vervolgens verdeeld over verschillende werkgroepen. Bij de samenstelling van de werkgroepen is gelet op een goede balans tussen inhoudelijke expertise, operationele kennis en analytische vaardigheden. Daarnaast is gezorgd voor vertegenwoordiging van meerdere consortiumpartners binnen iedere werkgroep, zodat kennis en ervaring vanuit verschillende organisaties konden worden ingebracht.

De analyseplannen, aanpak en resultaten werden besproken in de werkgroepen en ook in vier plenaire bijeenkomsten. Deze aanpak maakte het mogelijk om gedurende het project continu kennis en inzichten uit te wisselen tussen de verschillende werkgroepen. Tussen de bijeenkomsten door werkten de analisten verder aan de deelprojecten en stemden zij regelmatig binnen de werkgroep af over resultaten, knelpunten en vervolgstappen. De werkgroepen hebben zowel beschrijvende als verdiepende analyses uitgevoerd van de beschikbare data en hun werkwijze en resultaten opgeschreven. Gedetailleerde beschrijvingen van de specifieke onderzoeksvragen, methoden en resultaten zijn te vinden in de deelsecties van Hoofdstuk 3.

1.2.4 Werkpakket 5 – Aanbevelingen en kennisdisseminatie

In de afrondende fase van het project zijn de resultaten uit de verschillende werkpakketten samengebracht en vertaald naar een set aanbevelingen voor landelijke datastandaardisatie. Tijdens een gezamenlijke werkbijeenkomst zijn de belangrijkste bevindingen besproken en geconcretiseerd in aanbevelingen gericht op het verbeteren van de uniformiteit, kwaliteit en vergelijkbaarheid van gegevens tussen VR's.

De uitkomsten van het project zijn vastgelegd in deze eindrapportage. Daarnaast zijn de resultaten gedeeld tijdens diverse bijeenkomsten:

> Presentatie ‘Kladblokclustering – DATAPRO 112’, NIPV vakgroepoverleg datawetenschappen, 16 juni 2026
> Presentatie IV-event, 11 november 2026 (gepland)
> Presentatie leerarena, 12 november 2026 (gepland)
> Presentatie vakraad IV, 3 december 2026 (gepland).

Om de opgedane kennis breder beschikbaar te maken voor het werkveld wordt ook een eindsymposium georganiseerd waarin de belangrijkste bevindingen, lessen en aanbevelingen worden gepresenteerd aan betrokken stakeholders en geïnteresseerde partijen. De resultaten van dit project worden gebruikt voor de opdrachtformulering van de Community of Practice Vragenlijst om een uniforme vragenlijst te ontwikkelen waarmee in de 25 VR's een dataverzameling voor het 112-incidentafhandelingsproces kan worden opgezet. Daarnaast wordt er gewerkt aan separate kennisdocumenten over de verschillende analyse-onderwerpen die in dit rapport aan de orde komen.

2 Data-uitwisseling

De doelstelling van dit werkpakket was te komen tot uitwisseling van data die in de Werkpakketten 3 en 4 geanalyseerd konden worden. Dit betrof het inventariseren van de beschikbare databronnen en het afsluiten van een data-uitwisselingsovereenkomst die passend was voor de doelstellingen van dit project.

2.1 Data uit het Geïntegreerd Meldkamer Systeem (GMS)

We hebben gebruikgemaakt van GMS-data van de jaren 2020-2025 uit de zeven deelnemende VR's. Het GMS is het operationele systeem van de meldkamer waarin incidentmeldingen van burgers worden geregistreerd en waarmee hulpverlening door onder andere de brandweer in gang wordt gezet en gecoördineerd. Het betroffen gestructureerde data (incidentdata en incidentkarakteristieken) en de ongestructureerde data uit het Kladblok, dat bestaat uit de aantekeningen van de centralist om meldingen te kunnen volgen en coördineren. Het gedeelte van de data dat relevant is voor de VR's wordt opgeslagen in het datawarehouse van het NIPV en onder andere gebruikt voor de *Kerncijfers Veiligheidsregio's* (NIPV, z.d.).

Daarnaast is het aantal tankautospuiten per VR verzameld aan de hand van de *Kerncijfers Materieel* gepubliceerd door NIPV (z.d.). Deze cijfers worden pas sinds 2024 bijgehouden. In dit onderzoek wordt enkel de laatst beschikbare dataset (per 1 oktober 2025) voor de deelnemende regio's gebruikt. Naast de tankautospuiten beschikken de regio's vaak ook over een aantal specialistische voertuigen. De functie en benaming van deze voertuigen kan behoorlijk uiteenlopen en vaak zijn hun aantallen vrij laag. Dat maakt een vergelijking voor deze voertuigen tussen regio's lastig. Daarom is gekozen om alleen het meest voorkomende voertuig, de tankautospuit, in de analyses mee te nemen.

2.1.1 Persoonsgegevens

In afstemming met de Privacy Officers en Functionarissen Gegevensbescherming van de VR's en het NIPV is zorgvuldig vastgesteld hoe binnen het project zou worden omgegaan met mogelijk aanwezige persoonsgegevens in het GMS. De aandacht richtte zich hierbij specifiek op het zogenoemde Kladblok-veld, waarin centralisten tijdens de incidentafhandeling vrije tekst kunnen invoeren. Omdat persoonsgegevens geen meerwaarde hadden voor de beantwoording van de onderzoeksvragen, is besloten deze gegevens niet in de analyses te betrekken.

Om verwijdering van eventueel aanwezige persoonsgegevens mogelijk te maken, is vooraf een analyse uitgevoerd naar de aard en omvang van de persoonsgegevens die in het Kladblok voorkwamen. Op basis hiervan zijn richtlijnen opgesteld voor het identificeren en verwijderen van persoonsgegevens uit de aangeleverde datasets. Voor deze analyse is een Data Protection Impact Assessment (DPIA) uitgevoerd, waarin privacy risico's en beheersmaatregelen zijn beschreven. De resultaten van de analyse naar de aanwezigheid van persoonsgegevens worden in Hoofdstuk 3.2 besproken.

2.2 Aanvullende regionale data

Aanvullende gegevens die de zeven deelnemende VR's naast de data in GMS vastleggen over incidenten en incidentbestrijding zijn gebruikt om de GMS-gegevens te verrijken. Om deze aanvullende gegevens te identificeren en om inzicht te krijgen in het proces waarin deze gegevens tot stand komen, is er tussen november en december 2025 in elk van de deelnemende VR's een interview gehouden met een medewerker met kennis over de data van 112-incidentmeldingen en incidentbestrijding in de eigen regio.

Het interview was gestructureerd in drie fases: tussen melding van het incident en inzet, de inzet zelf en de fase na het incident (zie Bijlage 1). Daarnaast zijn enkele algemene vragen gesteld. De databronnen waarover de VR's beschikken en de systemen die hiervoor worden gebruikt zijn geïdentificeerd.

2.2.1 Procesbeschrijving op basis van interviews

De informatie verkregen uit de interviews is aangevuld door project- en stuurgroepleden van DATAPRO112. Op basis hiervan is de volgende procesbeschrijving gemaakt.

Fase 1 – van melding naar inzet

Melding

Wanneer een 112 melding binnenkomt op de Meldkamer stelt de centralist vragen aan de melder om de kenmerken van het incident te achterhalen (het intakeproces). De centralist is getraind in het kenmerkenschema om tot toepasselijke meldingsclassificaties te komen. De melding wordt geregistreerd in het GMS.

Inzetbehoefte

Direct na de incidentmelding en de initiële vaststelling van de classificering van een incident wordt een inzetbehoefte bepaald (het uitgifteproces). Met inzetbehoefte worden de typen voertuigen bedoeld die ingezet dienen te worden voor de incidentbestrijding. Dit gebeurt voor alle VR's door middel van rekenregels in GMS. Elke VR heeft vastgelegd welke soorten voertuigen voor welke type incidenten gealarmeerd dienen te worden op basis van het regionale risicoprofiel.

Inzetvoorstel

De inzetbehoefte wordt vertaald naar een inzetvoorstel. Het inzetvoorstel bevat de specifieke voertuigen die gekoppeld worden aan het incident voor de uitruk. De VR's gebruiken verschillende methoden om tot een inzetvoorstel te komen. Zo wordt het inzetvoorstel voor de VRAA bepaald met behulp van de kazernevolgordetabel (KVT). Deze statische tabel bevat per verzorgingsgebied de volgorde van alarmeren van voertuigen en hun standplaatsen. De KVT wordt opgesteld en beheerd in CARE (Falck) en ingelezen in GMS voor de bepaling van inzetvoorstellen. Elk verzorgingsgebied is opgedeeld in vakken. Voor een incident in een bepaald vak volgt een lijst van voertuigen die in volgorde gealarmeerd kunnen worden. Er zijn verschillende lijsten voor verschillende typen voertuigen en incidenten en voor dag- en nachtsituaties. De lijsten worden beheerd door een liaison meldkamer en jaarlijks automatisch verwerkt in GMS.

In de VRGZ, VRIJ, VRMWB, VNOG, VGGM en VRT wordt dynamisch alarmeren toegepast. Anders dan bij het gebruik van een KVT is er dan geen vaste koppeling tussen het incidenttype en de eenheid die wordt opgeroepen voor inzet, maar wordt er in het

inzetvoorstel rekening gehouden met actuele voertuigbeschikbaarheid, de locatie van het incident en de GPS-positie van de voertuigen. Dynamisch alarmeren is bij de VR's op verschillende manieren geïmplementeerd met verschillende tools.

Als het inzetvoorstel gegenereerd is, kan een centralist nog wijzigingen aanbrengen voordat alarmering plaatsvindt. Op verzoek van een bevelvoerder of officier van dienst kan ook afgeweken worden van het inzetvoorstel. Dit kan door de centralist expliciet vastgelegd worden in het kladblok, maar volgt in ieder geval uit de voertuigen die aan een incident gekoppeld zijn. Over het algemeen wordt alleen in uitzonderlijke gevallen afgeweken van het inzetvoorstel.

Uitruk
Informatie over welke eenheden daadwerkelijk zijn uitgerukt volgt met name uit GMS. Eenheden worden in GMS aan een incident gekoppeld, waarna zij ook hun status kunnen doorgeven. De statussen in GMS zijn afhankelijk van handmatige handelingen van eenheden, waardoor deze niet altijd accuraat zijn. De VRGZ en VNOG gebruiken daarom een automatische manier om de statussen te achterhalen (autostatus) op basis van GPS-locaties. De VRT gebruikt ook autostatus naast handmatig statussen. De GPS-locaties van eenheden worden op verschillende manier bijgehouden via verschillende systemen. Deze autostatussen zijn niet altijd helemaal correct, bijvoorbeeld wanneer een incidentlocatie niet klopt. Er worden verschillende manieren gebruikt om een uitruk te verifiëren, bijvoorbeeld via vragenlijsten of opkomstcijfers.

Inzet
In de meeste VR's wordt de status 'Ter plaatse' in GMS gezien als inzet, ook als er geen werkzaamheden zijn uitgevoerd. Dit is in overeenstemming met de definitie die het NIPV hanteert voor het dashboard *Kerncijfers Incidenten* (NIPV, z.d.). De inzet van specifieke voertuigen (TS, HV, AL, et cetera) en functionarissen die gebruikmaken van een specifiek voertuig (OvD, HOvD, AGS, et cetera) kunnen op die manier uit de voertuigstatussen worden afgeleid.

Fase 2 – tijdens het incident
Tijdens het incident vindt er gegevensopslag plaats in GMS en in enkele andere systemen. De meeste gegevens komen tot stand door communicatie of registratie door betrokken hulpverleners. Het gebruik van sensoren voor dataverzameling in de praktijk is nog beperkt, maar het is te verwachten dat dit in de toekomst toe zal nemen.

Gegevensopslag tijdens het incident
Vanaf de incidentlocatie wordt meestal mondeling gecommuniceerd met de meldkamer. De meldkamercentralist legt de informatie vast in het Kladblok of de karakteristiekvelden van GMS. Alle acties in GMS, zoals aanvullingen of wijzigingen van gegevens, worden gelogd. Bij sommige regio's hebben hulpverleners ter plaatse, zoals de bevelvoerder, Officier van Dienst (OvD) of informatiemanager (IM) ook toegang tot het kladblok.

Wanneer er tijdens de incidentbestrijding wordt opgeschaald, betekent dit dat er extra materieel en/of personeel nodig is. Dit gebeurt meestal via nadere berichten zoals 'grote brand'. Hieraan is vaak een standaard aantal voertuigen gekoppeld. Dit kan verschillen per regio. Opschaling wordt vaak als karakteristiek aan het incident gekoppeld. Bijvoorbeeld: de classificatie 'kleine brand' gaat over in 'middelbrand' als een bevelvoerder vraagt om een extra TS. Ook de aanvraag van specialistische eenheden gaat vaak via een karakteristiek.

Gegevensopslag tijdens een opgeschaald multi-incident (GRIP)
Wanneer een incident multidisciplinaire inzet vraagt, kan er worden opgeschaald naar GRIP-1 of hoger. GRIP-opschaling komt vaak voor bij grootschalige incidenten, maar niet altijd. Bij GRIP-situaties leggen de calamiteitencoördinator (CaCo) op de meldkamer of de IM gegevens vast in het Landelijk Crisis Management Systeem (LCMS). Vaak wordt ter plaatse ook een verslag bijgehouden van overlegmomenten.

Fase 3 – na het incident
Na het incident worden er bij alle VR's aanvullende gegevens opgeslagen. De redenen hiervoor en de gebruikte methoden verschillen tussen de VR's. De vragenlijst is een veelgebruikte vorm. Daarnaast worden er soms rapporten bijgehouden door de Officier van Dienst (OvD-rapporten). Deze zijn echter bedoeld voor persoonlijk gebruik en worden niet beschikbaar gesteld voor data-analyse. Doorgaans worden vragenlijsten ingevuld door de bevelvoerder, maar soms ook door de OvD of chauffeur van specialistische voertuigen.

De inzet tijdens een incident wordt voornamelijk geregistreerd voor bedrijfsvoering, zoals de uitbetaling van vrijwilligers, maar de informatie wordt ook gebruikt om van incidenten te kunnen leren. Soms wordt informatie uit GMS gebruikt om een vragenlijst al gedeeltelijk automatisch in te vullen; een bevelvoerder kan deze informatie later aanpassen (bijvoorbeeld als een incident een andere aard had dan in eerste instantie gemeld).

Tabel 2.1 Overzicht van beschikbare datatypen per VR. Een vraagteken in een cel betekent dat de beschikbaarheid van dit type data onbekend is

Type	VGGM	VNOG	VRAA	VRGZ	VRIJ	VRMWB	VRT
GMS	Ja	Ja	Ja	Ja	Ja	Ja	Ja
Inzet-behoefte	GMS reken-regels	GMS reken-regels	GMS reken-regels	GMS reken-regels	GMS reken-regels	GMS reken-regels	GMS reken-regels
Inzet-voorstel	Dynamisch alarmeren	Dynamisch alarmeren	KVT	Dynamisch alarmeren	Dynamisch alarmeren	Dynamisch alarmeren	Dynamisch alarmeren
Voertuig-status	GMS	GMS & autostatus	GMS	GMS & autostatus	GMS, plan overstap autostatus	GMS, plan ver-vangen met tele-metrie	GMS & autostatus
GPS-voertuig	Nee	Ja		Ja	Nee	Ja	Ja
Pagers	?	?	?	Ja	?	Ja	Ja
Bevelvoer-ders-verslag	?	Ja	Ja	Nee	Ja	?	Ja
Voertuig-onderhoud	Nee	Gepland voor 2026	Nee	Nee	Nee	Ja	Nee

Type	VGGM	VNOG	VRAA	VRGZ	VRIJ	VRMWB	VRT
Waterver-bruik	Nee	Gepland voor 2026	Nee, wel in verleden	Nee	Nee	Ja	Nee
LCMS	Ja	Ja	Ja	?	Ja	Ja	Ja
Vragenlijst	Alleen woning-branden	Ja	Ja. Onbekend of in gebruik	Nee, in ontwikke-ling	Ja, per 2026	Ja, nieuwe versie in ontwikke-ling	Ja, uitgebreid
OvD-rapporten	Ja	Ja	Ja	Nee	Nee	?	Nee

Het gebruik van vragenlijsten
De meeste VR's maken gebruik van vragenlijsten die zij in hun regionale applicaties faciliteren. Er is landelijke standaardisatie op applicatieniveau en de deelnemende regio's verwerken data in drie verschillende applicaties. In de VRGZ is nog geen vragenlijst geïmplementeerd, maar is dit wel gepland. De VGGM maakt geen gebruik van een specifieke tool.

Bij de VRAA wordt de daadwerkelijke inzet van een eenheid gebaseerd op de gegeven statussen in GMS. Bij de andere regio's wordt hier specifiek naar gevraagd in de vragenlijst, waardoor het antwoord kan afwijken van de statussen in GMS en dus als verificatie kan dienen. Een aantal regio's, behalve de VRAA en VRIJ, neemt in de vragenlijst de meldingsclassificatie op, waardoor het mogelijk is om de data van GMS te verifiëren. Bij VRGZ, VRMWB en VRT heeft de invuller de mogelijkheid de meldingsclassificaties aan te passen.

Een aantal regio's verifieert de opschaling door dit nog extra uit te vragen. De opschaling van een incident is dan vaak onderdeel van de vragenlijst, behalve bij de VGGM. Vaak wordt hierbij de opschaling gebruikt zoals die in GMS is vastgelegd; bij de VRMWB en VRT kan dit apart ingevuld worden. De vragenlijsten bevatten ook een vraag over bijzonderheden tijdens het incident of de inzet.

Veel vragenlijsten zijn gecategoriseerd naar type incident en/of inzet. Dit kan gekoppeld zijn aan de meldingsclassificaties. Globaal wordt een indeling gemaakt naar de vier kerntaken van de brandweer: brandbestrijding, hulpverlening, bestrijding van incidenten met gevaarlijke stoffen en waterongevallen. De specifieke vragen die gesteld worden over de inzet bij ieder van deze categorieën verschillen sterk van regio tot regio. In deze rapportage wordt aangegeven welke regio's vragen hebben opgenomen die specifiek ingaan op de inzet binnen deze categorieën. Denk hierbij aan vragen over waterverbruik bij brand, verrichte metingen bij gevaarlijke stoffen, gebruikte bevrijdingstechnieken en/of materialen of ingezette specialismen.

Bijna alle regio's stellen vragen over de inzet voor alle vier de categorieën, met uitzondering van VRIJ, waar geen specifieke vragen gesteld worden over de categorie hulpverlening. Specifieke vragen over de inzet maken op dit moment geen deel uit van de vragenlijst bij VRAA; de intentie is om vragen toe te voegen over brandbestrijding. Bij de VGGM worden alleen vragen gesteld over woningbranden, maar niet specifiek over de inzet. In de

vragenlijsten die de regio's na het incident invullen, komen ook additionele of verdiepende vragen voor, waarmee wordt ingegaan op specifieke thema's. Deze interessegebieden, bijvoorbeeld slachtoffers, brandoorzaak, lekkage van gevaarlijke stoffen en zaken gerelateerd aan de energietransitie verschillen tussen regio's. De resultaten en genoemde interessegebieden zijn samengevat in Tabel 2.2 op de volgende pagina.

Tabel 2.2 Inzetthema's en interessegebieden per VR

	VGGM	VNOG	VRAA	VRGZ	VRIJ	VRMWB	VRT
Vragenlijst		Aparte tool	Aparte tool	(gepland)	Aparte tool	Aparte tool	Aparte tool
Inzet verificatie	ja	ja	GMS	(ja)	ja	ja	ja
Meldings-classificaties	nee, GMS	ja		(ja)		ja	ja
Opschaling		ja	nee, GMS	nee, GMS	nee, GMS	ja	ja
Bijzonderheden	ja	ja	ja	(ja)	ja	ja	ja
Categorisering van incidenten op soort		ja		(ja)	ja	ja	ja
Optreden brand		ja	(ja)	(ja)	ja	ja	ja
Optreden hv		ja		(ja)		ja	ja
Optreden ibgs		ja		(ja)	ja	ja	ja
Optreden wo		ja		(ja)	ja	ja	ja
Interessegebieden							
Reddingen					ja		ja
IBGS		ja		ja	ja	ja	ja
Waterongeval		ja			ja	ja	ja
Loos alarm / nodeloos alarmeren		ja				ja	ja
Agressie tegen brandweer			ja				ja
Gewonden en slachtoffers	ja		ja		ja		ja
Woningbranden	ja	ja			ja		ja
Accubranden			ja	ja	ja		
LNG				ja			
Scheepvaart				ja			

hv = hulpverlening, ibgs = inzet bestrijding gevaarlijke stoffen, wo = waterongevallen, IBGS = incidentbestrijding gevaarlijke stoffen, LNG = Liquified natural gas, nee = niet aanwezig, ja = aanwezig, (ja) = in ontwikkeling.

2.2.2 Data-uitwisseling slimme vragenlijst

Voor dit project zijn, naast de reguliere databronnen, aanvullende data uitgewisseld. Binnen VRT wordt na afloop van een incident een slimme vragenlijst (SLV) ingevuld. Deze vragenlijst wordt doorgaans ingevuld door de bevelvoerder of voertuigbedienaar van de betrokken eenheid. Omdat bij één incident meerdere eenheden of operationele teams betrokken kunnen zijn, kunnen voor eenzelfde incident meerdere vragenlijsten beschikbaar zijn. De vragenlijsten bevatten informatie over incidenten die zowel binnen als buiten de regio hebben plaatsgevonden en afkomstig kunnen zijn van verschillende meldkamers. Op basis van het incidentnummer konden de vragenlijstgegevens worden gekoppeld aan GMS-data. De koppeling werd uitgevoerd voor de periode van 2020 tot en met 2025, de afgesproken periode van datalevering binnen het DATAPRO112-project.

2.3 Data van het Centraal Bureau voor de Statistiek (CBS)

Voor een aantal analyses in het volgende hoofdstuk was het nodig diverse kenmerken te koppelen aan incidentdata en VR's. Zo is voor het onderzoek naar algemene kenmerken van de gemelde incidenten in Hoofdstuk 3.1 gebruikgemaakt van diverse CBS-tabellen om de kenmerken van de VR's te bepalen. Voor het aantal inwoners in de jaren 2020-2025 is gebruikgemaakt van de CBS-tabellen met identificatienummers 84721NED, 84929NED, 85067NED, 85385NED, 85755NED, en 86059NED. Voor totale weglengte in de jaren 2020-2025 is tabel met nummer 70806NED gebruikt. Voor woningvoorraad (totaal woning en totaal niet-woning) voor de jaren 2020-2025 was dat tabelnummer 86098NED. Ten tijde van de analyse (februari 2026) was de meest recente tabel met informatie over bodemgebruik de tabel met identificatienummer 86211NED. Deze tabel geeft de situatie weer in het jaar 2022. Aangenomen wordt dat het bodemgebruik uit 2022 voldoende representatief is voor de beschouwde jaren (2020-2025). De gebruikte tabellen geven informatie op gemeenteniveau. Voor dit onderzoek werden de cijfers per jaar geaggregeerd tot VR niveau.

Voor het onderzoek over procesanalyses in Hoofdstuk 3.6 is gebruikgemaakt van de *Kerncijfers Wijken en Buurten*. Deze tabellen bevatten onder andere gegevens over de sociaaldemografische kenmerken van een wijk of buurt. Deze gegevens worden per jaar verzameld door het CBS en zijn dus ook beschikbaar voor de jaren 2020 tot en met 2025. Het betreft CBS-tabellen met identificatienummers 84799NED, 85039NED, 85318NED, 85618NED, 85984NED en 86165NED. De cijfers konden op basis van buurtcodes gekoppeld worden aan de incidentdata.

2.4 Gebruikte software voor data laden en opschonen

Voor het laden van de data uit de databases is het 'dataladen-Python-package' geschreven. Dit package is beschikbaar in de Gitlab repository (Gitlab, DATAPRO112 - dataladen, z.d.) en vereist ten minste Python versie 3.11. De ondersteunende packages zijn opgenomen in het pyproject.toml-bestand in deze repository.

2.5 Conclusies over huidige data-uitwisseling

Op basis van interviews die zijn afgenomen, kan worden geconcludeerd dat er grote overeenkomsten zijn in het 112-incidentafhandelingsproces, maar dat er verschillen zijn in de gegevens die over dit proces worden vastgelegd.

Globaal genomen wordt na een melding in elke VR het inzetvoorstel bepaald in de meldkamer na de vaststelling van de inzetbehoefte. De manier waarop verschilt tussen de regio's. Relevante data betreffen de rekenregels voor de bepaling van het inzetvoorstel uit GMS, de KVT en het inzetvoorstel zelf, waar beschikbaar.

Na afloop van het incident worden incidentkarakteristieken in meer of mindere mate vastgelegd met vragenlijsten. De meeste VR's aangesloten bij DATAPRO112 werken met vragenlijsten. De incidentthema's die aan de orde komen in de vragenlijsten verschillen tussen VR's. Incidentbestrijding gevaarlijke stoffen (IBGS) wordt bijvoorbeeld bij vier van de zeven regio's uitgevraagd. Waterongevallen en accubranden komen elk bij drie VR's terug in de vragenlijst. De keuze van interessegebieden heeft mogelijk te maken met de ligging van de VR's en de aldaar optredende veiligheidsrisico's.

Zoals bekend, is het GMS vooral bedoeld als communicatiemiddel tijdens de incidentbestrijding. De data in GMS geven daarom niet altijd een goede weergave van de werkzaamheden van de VR en zijn niet altijd bruikbaar voor een goede analyse van het verloop van het incident. De vragenlijsten worden achteraf ingevuld op het moment dat met enige afstand en rust op het incident kan worden teruggekeken. Aan de hand van de vragenlijstdata kunnen de data in GMS geverifieerd worden. Deze data zijn heel geschikt om verschillen in meldingsverwerking tussen regio's in kaart te brengen en mogelijk voorstellen tot uniformering te doen. Daarnaast kunnen de inzetbehoeften en -voorstellen naast de daadwerkelijke inzet en het optreden worden gelegd. Dit kan als input dienen voor het dynamisch inzetadvies en de voorspelling van opschaling.

3 Data-analyse

In de Werkpakketten 3 & 4 zijn analyses uitgevoerd van de beschikbare data. Hiervoor hebben we in een werksessie onderzoeksvragen vastgesteld, waaraan in de weken erna is gewerkt. Dit hoofdstuk is ingedeeld per onderzoeksvraag, en bevat steeds een korte inleiding, en een beschrijving van de methode, resultaten en conclusies. De volgende onderzoeksvragen komen aan de orde:

3.1) Welke inzichten geven meldingsclassificaties over de aard en omvang van incidenten binnen VR's en hoe kunnen verschillen tussen VR's worden beschreven in samenhang met regiokenmerken zoals aantal inwoners, aantal woningen en grondoppervlak?

3.2) Bevatten kladblok regels persoonsgegevens en kunnen deze voldoende worden verwijderd, zodat deze data kan worden gebruikt in onderzoek? En welke datamanagement stappen zijn nodig om het kladblok bruikbaar de maken voor data-analyse?

3.3) Hoe wordt het karakteristieken veld van het GMS gebruikt en welke verdiepende informatie geeft dit veld over de aard van een incident?

3.4) Zijn de karakteristiekvelden van brandmeldingen van de VR's voldoende uniform of is het mogelijk om op basis van deze velden de VR's te herkennen?

3.5) In hoeverre kan incidentinformatie van GMS geverifieerd worden met data uit een aanvullende incidentvragenlijst?

3.6) Wat is de doorlooptijd van incidentafhandeling en welke factoren zijn hierop van invloed? Ook is onderzocht wat de buurtkenmerken zijn in relatie tot incidentmeldingen.

3.7) In hoeverre kunnen woningbranden met slachtoffers worden geïdentificeerd op basis van meldkamerdata en specifiek de informatie die is vastgelegd in kladblokregels?

3.8) In hoeverre is de inhoud van de kladbloktekst kenmerkend voor een VR en veranderd over de tijd? En in hoeverre komt de typering van incidenten op basis van de kladbloktekst overeen met de bestaande meldingsclassificaties en kunnen er nieuwe meldingsclassificaties geïdentificeerd worden die beter passen bij de data?

3.9) In hoeverre kunnen met behulp van trendanalyse bruikbare patronen en ontwikkelingen worden geïdentificeerd in ongestructureerde kladblokregels uit meldkamers van meerdere VR’s?

3.10) Welke incident- en contextkenmerken hangen samen met opschaling bij gebouwbranden, nadat de bevelvoerder ter plaatse is gekomen? En in hoeverre kan opschaling worden verklaard en voorspeld op basis van de tot dat moment beschikbare gegevens?

3.1 Algemene kenmerken van de data

3.1.1 Inleiding

Voor een goed begrip van de data is een exploratieve data-analyse uitgevoerd. We hebben bekeken hoeveel incidentmeldingen er zijn in de deelnemende regio's en hoe deze zich verhouden tot elkaar als je meeneemt dat er verschillen zijn in regiokenmerken. Dergelijke exploratieve analyses worden vaak uitgevoerd voordat wordt overgegaan tot het doen van statistische analyses en het bouwen van modellen. In dit project is het gebruikt om de belangrijkste datakenmerken te identificeren, uitzonderingen aan het licht te brengen en patronen te herkennen.

In hoofdstuk 3.1 worden de aantallen gemelde incidenten opgesplitst naar VR en jaar voor de diverse meldingsclassificaties en visueel weergegeven. Vanwege de diverse grootte en kenmerken van de deelnemende VR's werden er aanzienlijke verschillen in de aantallen gemelde incidenten verwacht. Als een VR meer woningen heeft, mogen er immers ook meer woningbranden verwacht worden. Daarom zijn de aantallen gemelde incidenten geschaald naar VR-kenmerken zoals aantal inwoners, aantal woningen of grondoppervlak.

In de volgende paragraaf wordt de analysemethode toegelicht. Daarna volgen de regiokenmerken. Vervolgens worden de incidenten voor de interessante meldingsclassificaties besproken per onderwerp. Daarna worden de aantallen gemelde incidenten over de tijd getoond.

3.1.2 Methode

Voor aantallen incidenten is gebruikgemaakt van de gemelde incidenten uit het GMS. Er zijn incidenten geselecteerd waarbij de brandweercentralist een brandweereenheid gealarmeerd heeft. Er moest sprake zijn geweest van een incident met prioriteit 1 (spoed) of prioriteit 2 (geen spoed) waarbij de brandweer is uitgerukt[2] en de hoofdmeldingsclassificatie was ingevuld. Deze selectie is identiek aan de selectie die gebruikt wordt voor de gepubliceerde geaggregeerde data op het openbare dashboard *Kerncijfers* (NIPV, z.d.). De hier gebruikte aantallen zijn dan ook identiek aan die uit het dashboard. Evenals in dit dashboard spreken we ook hier van 'gemelde incidenten'.

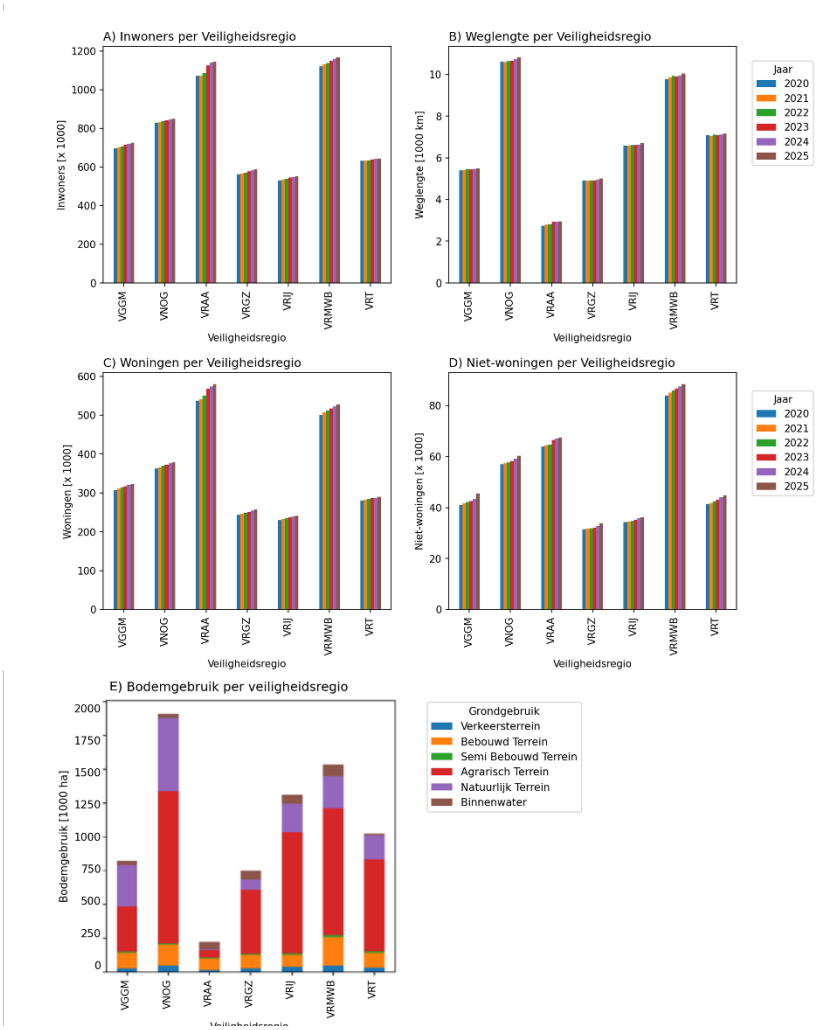
Voor de VR-kenmerken is gebruikgemaakt van de data zoals weergegeven in paragraaf 2.3. Voor de figuren en analyses in dit hoofdstuk is gebruikgemaakt van Python versie 3.13. De code is beschikbaar in een Gitlab repository (Gitlab, DATAPRO112 – vergelijking regio's, z.d.).

3.1.3 Regiokenmerken

Figuur 3.1 op de volgende pagina laat zien dat de VR's van elkaar verschilden in aantal inwoners, weglengte, aantal woningen en overige panden. De inwoners, panden en weglengte binnen de regio lieten een kleine jaarlijkse groei zien. Er zat een kleine sprong van 2022 naar 2023 in de aantallen voor VRAA. Dit heeft vermoedelijk te maken met de gemeentelijke fusie tussen Weesp en Amsterdam in maart 2022, waardoor de VRAA gegroeid is. VRAA heeft het kleinste oppervlak en de kortste totale weglengte, maar wel veel inwoners. Terwijl het aantal inwoners in VRAA en VRMWB nagenoeg gelijk is, is het aantal niet-woningen in VRMWB duidelijk hoger.

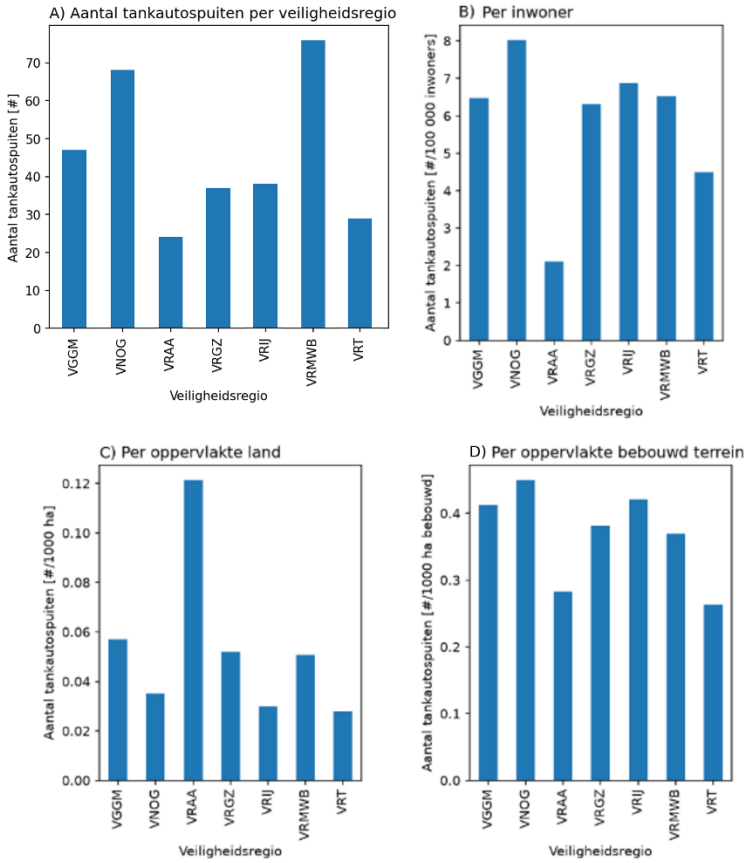
[2] Er is sprake van 'inzet', 'afgebroken alarmering' of 'afgebroken uitruk'.

Figuur 3.1E laat het aantal tankautospuiten en bodemgebruik per regio zien. De figuur toont dat de regio's VNOG en VRMWB de meeste tankautospuiten bevatten. De figuur laat ook zien dat VRAA het kleinste grondgebied heeft en ook een relatief laag percentage agrarisch en natuurlijk terrein. De regio's VNOG en VRMWB hebben het grootste grondgebied.



Figuur 3.1 Verschillen tussen regio's in (A) het aantal inwoners, (B) weglengte, (C) het aantal woningen, (D) het aantal overige panden, en (E) het bodemgebruik in 2022

Naast het absoluut aantal tankautospuiten, is in Figuur 3.2 ook het relatief aantal tankautospuiten per regio weergegeven, geschaald naar aantal inwoners, landoppervlak, en oppervlakte bebouwd terrein. Opvallend is het relatief lage aantal voertuigen per inwoner in VRT en met name in VRAA. Als er echter wordt geschaald naar aantal tankautospuiten per oppervlakte land (Figuur 3.2C), dan ligt het aantal tankautospuiten in VRAA juist veel hoger dan in de overige regio's. Er kan ook naar oppervlakte bebouwd terrein geschaald worden. Dan blijkt dat de aantallen tankautospuiten tussen de regio's redelijk vergelijkbaar zijn (zie Figuur 3.2D).



Figuur 3.2 Het (A) absoluut aantal tankautospuiten per 1 oktober 2025, het relatief aantal tankautospuiten (B) per 100.000 inwoners, (C) per oppervlakte land in de regio, en (D) per oppervlakte bebouwd terrein

3.1.4 Aantallen gemelde incidenten

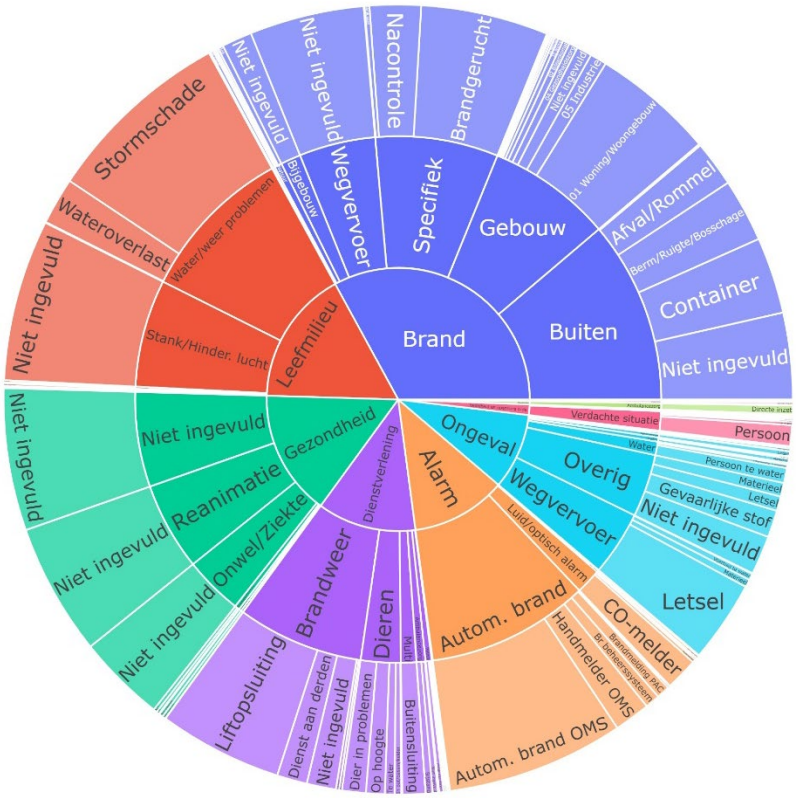
In de jaren 2020 tot en met 2025 waren er in totaal 245.061 incidentmeldingen. Het aantal incidentmeldingen is over de jaren ongeveer constant gebleven. Wel waren er grote verschillen tussen regio's: VRAA had ongeveer vier keer zoveel gemelde incidenten als VRIJ (72689 versus 18181).

Tabel 3.1 Aantallen gemelde incidenten per VR en jaar

VR	2020	2021	2022	2023	2024	2025	Totaal per regio (%)
VGGM	4694	4566	5612	4656	4599	4941	**29068 (12%)**
VNOG	4702	4228	5434	4697	4693	5464	**29218 (12%)**
VRAA	11769	11941	13181	11704	12018	12076	**72689 (30%)**
VRGZ	4282	4072	4519	3720	3844	4290	**24727 (10%)**
VRIJ	2834	2749	3382	3042	3058	3116	**18181 (7%)**
VRMWB	8840	7412	8922	8082	7046	7792	**48094 (20%)**
VRT	4133	3875	4388	3593	3492	3603	**23084 (9%)**
Totaal per jaar	**41254**	**38843**	**45438**	**39494**	**38750**	**41282**	**245061 (100%)**

In GMS krijgt elk gemeld incident naast een hoofdmeldingsclassificatie ook subclassificaties toegekend. Deze classificaties zijn incidenttyperingen op drie niveaus van specificatie. Zo kan een incident een hoofdmeldingsclassificatie ‘Brand’ hebben, een tweede niveau meldingsclassificatie ‘Buiten’ en een derde meldingsclassificatie ‘Container’. Een compleet en actueel overzicht van de gebruikte landelijke meldingsclassificaties is beschikbaar op de website van de meldkamer (Landelijke Meldkamer Samenwerking, z.d.). In Figuur 3.3 is de verdeling van de incidenten over de drie niveaus van meldingsclassificatie weergegeven voor de betrokken VR’s voor de jaren 2020-2025. De figuur illustreert hoe vaak de brandweer gealarmeerd is. Zo is zij vaak gealarmeerd bij gebouwbranden (18758 gemelde incidenten; 7.7%) en buitenbranden (27443 gemelde incidenten; 11.2%), automatische alarmen (24477 gemelde incidenten; 10.0%), liftopsluitingen (12438 gemelde incidenten; 5.1%) en stormschades (18877 gemelde incidenten; 7.7%). Het aantal gemelde incidenten hangt niet rechtstreeks samen met hun impact. Natuurbrandmeldingen vormen bijvoorbeeld maar een klein deel van alle meldingen en zijn daarom niet goed zichtbaar in de figuur, maar kunnen wel een grote impact hebben op de brandweer en de maatschappij.

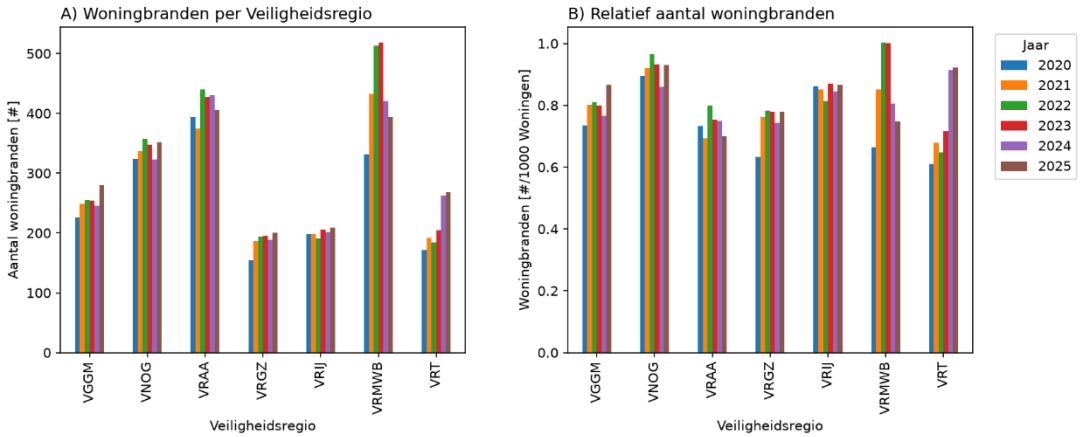
Niet alle subclassificaties zijn ingevuld. Figuur 3.3 laat zien dat voor gemelde incidenten met hoofdmeldingsclassificatie ‘Gezondheid’ de classificatie op het derde niveau vaak niet is ingevuld. Alle meldingsclassificaties op het hoofdniveau zijn ingevuld vanwege de dataselectie (zie Methode). Op het tweede niveau hebben 14954 (6.1%) gemelde incidenten geen classificatie, en op het derde niveau 87753 (35.8%).



Figuur 3.3. Het aantal incidenten naar eerste, tweede en derde meldingsclassificatieniveau weergegeven in een cirkeldiagram

3.1.5 Woningbrand

In totaal waren er tussen 2020 en 2025 40761 woningbrandmeldingen. Het aantal jaarlijks gemelde incidenten met meldingsclassificatie woningbrand per regio is afgebeeld in Figuur 3.4A. Er was sprake van een lichte toename van het aantal woningbrandmeldingen in VRT tussen de jaren 2023 en 2024. Dit lijkt te maken hebben met het anders classificeren van schoorsteenbrand[3]. Het aantal meldingen van woningbrand bleef in de overige regio's vrij gelijk over de tijd. Er zijn wel grote verschillen in het aantal gemelde incidenten met meldingsclassificatie woningbrand tussen regio's. Het aantal woningen verschilt ook aanzienlijk tussen de regio's (Figuur 3.1C). Daarom mag het verwacht worden dat het aantal woningbranden hoger ligt in regio's met meer woningen. In Figuur 3.4A is het aantal woningbrandmeldingen per VR weergegeven. In Figuur 3.4B is dit geschaald naar het aantal woningen. Wanneer het aantal woningbrandmeldingen wordt geschaald naar het aantal woningen, dan wordt duidelijk dat elke regio ongeveer evenveel brandmeldingen heeft, namelijk circa 0,8 per 1000 woningen.

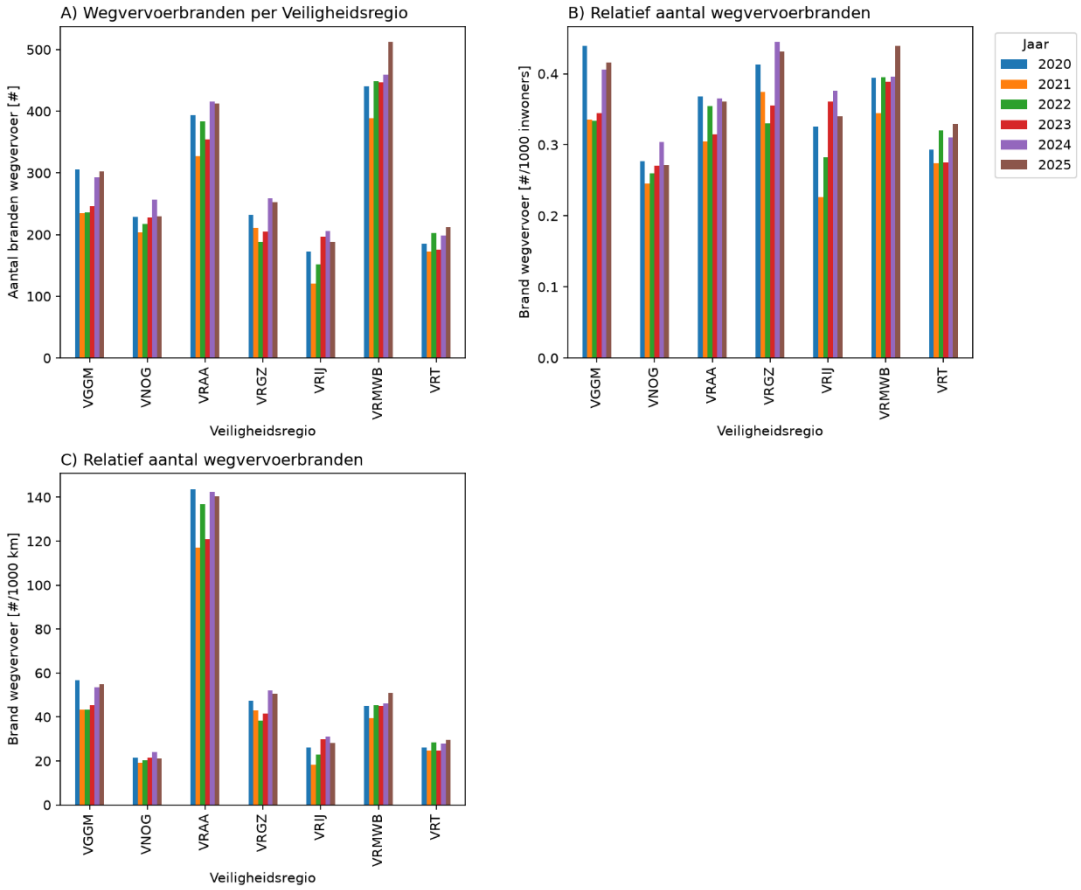


Figuur 3.4 Aantal gemelde incidenten met meldingsclassificatie woningbrand per VR en per jaar; (A) absolute aantallen en (B) aantallen per 1000 woningen

3.1.6 Brand wegvervoer

Het aantal jaarlijks gemelde incidenten met meldingsclassificatie brand wegvervoer per VR wordt getoond in Figuur 3.5A. Deze incidenten bestaan bijvoorbeeld uit autobranden. De aantallen verschillen relatief weinig van jaar tot jaar, maar ook hier zijn er wel aanzienlijke verschillen tussen de regio's. Dit heeft vermoedelijk te maken met het aantal voertuigen dat aanwezig is in de regio. Hier wordt het aantal inwoners als proxy gebruikt voor het aantal voertuigen, waarbij wordt verondersteld dat een vast percentage inwoners een voertuig bezit. Deze aanname is niet helemaal correct: met name in de stedelijke gebieden ligt het autobezit namelijk lager (CBS, 2026). Daadwerkelijke gegevens over autobezit zijn niet gebruikt in dit project, maar kunnen meegenomen worden in eventueel vervolgonderzoek. Geschaald naar het aantal inwoners is het aantal wegvervoerbranden min of meer constant over de regio's (zie Figuur 3.5B). Er kan ook geschaald worden naar de totale weglengte in de regio. Uit Figuur 3.5C blijkt dat verschillen in het aantal gemelde incidenten tussen de regio's dan juist toenemen.

[3] Persoonlijke communicatie met Joop Wessels.

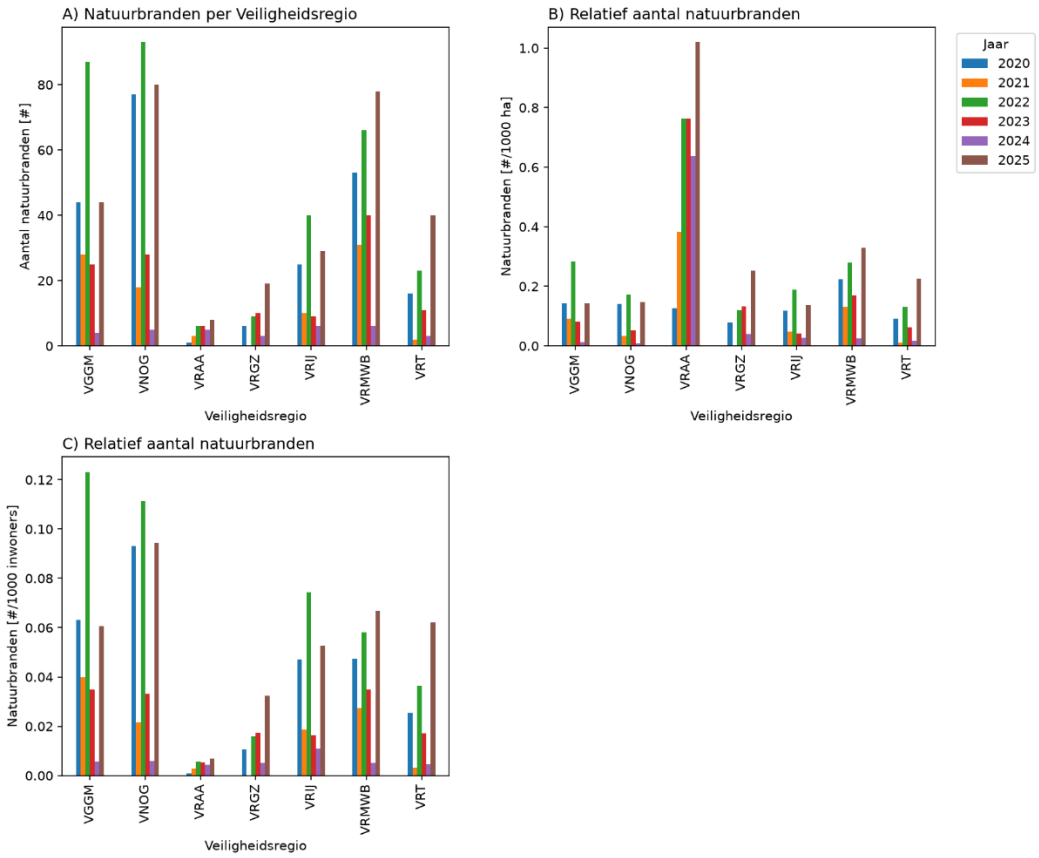


Figuur 3.5 Aantal gemelde incidenten met meldingsclassificatie brand wegvervoer per VR en per jaar; (A) absolute aantallen, (B) aantallen per 1000 inwoners en (C) aantallen per weglengte

3.1.7 Natuurbrand

De jaarlijkse aantallen gemelde incidenten met meldingsclassificatie natuurbrand[4] staan weergegeven in Figuur 3.6A. De aantallen verschillen aanzienlijk van jaar tot jaar, wat veroorzaakt wordt door verschillen in droogte en weersituaties. Het KNMI (z.d.) laat zien dat de jaren 2020, 2022 en 2025 veel droger waren dan de tussenliggende jaren, wat overeenkomt met de pieken in de figuur. Het aantal natuurbranden per oppervlakte natuurterrein ligt vrij hoog in VRAA (Figuur 3.6B), hoewel deze regio maar weinig agrarisch en natuurlijk terrein bevat (Figuur 3.1F). Voor de overige regio's is het aantal natuurbranden per 1000 hectare natuur een heel stuk lager. Wanneer het aantal gemelde natuurbranden wordt weergegeven per 1000 inwoners, zien we dat VGGM en VNOG er wat hoger uitspringen en VRAA juist heel laag uitkomt. Dit laat zien dat de relatie tussen natuurbranden, inwoners en oppervlakte natuurterrein ingewikkeld is en niet in een simpele exploratieve analyse te vangen is. Recreatiedruk en type vegetatie zijn andere mogelijke belangrijke indicatoren. Dit is echter niet verder onderzocht binnen dit project.

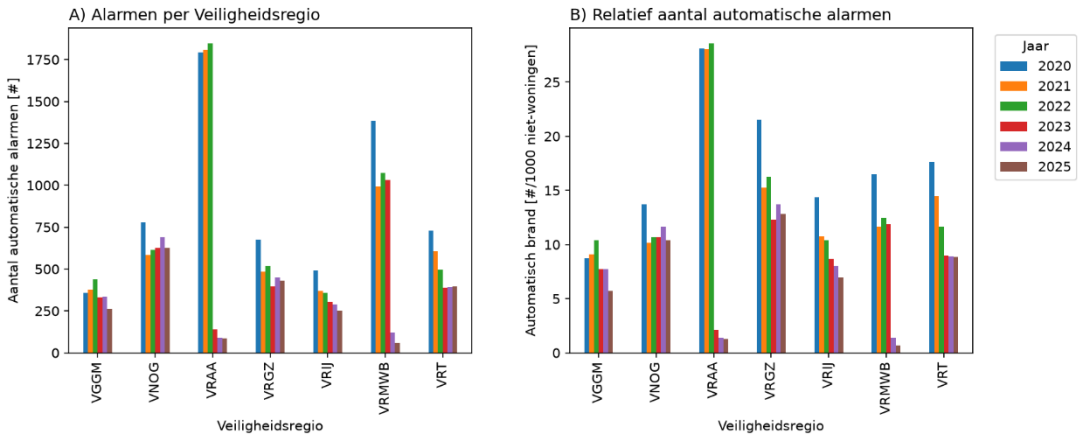
[4] Hoofdclassificatie 'brand', 2e niveau classificatie 'natuur'. Deze selectie is identiek aan de voorlopige cijfers op het dashboard natuurbranden (NIPV, z.d.).



Figuur 3.6 Het aantal gemelde incidenten met meldingsclassificatie natuurbrand per VR en per jaar; (A) absolute aantallen, (B) aantallen per 1000 hectare natuurlijk terrein en (C) aantallen per 1000 inwoners

3.1.8 Alarmen

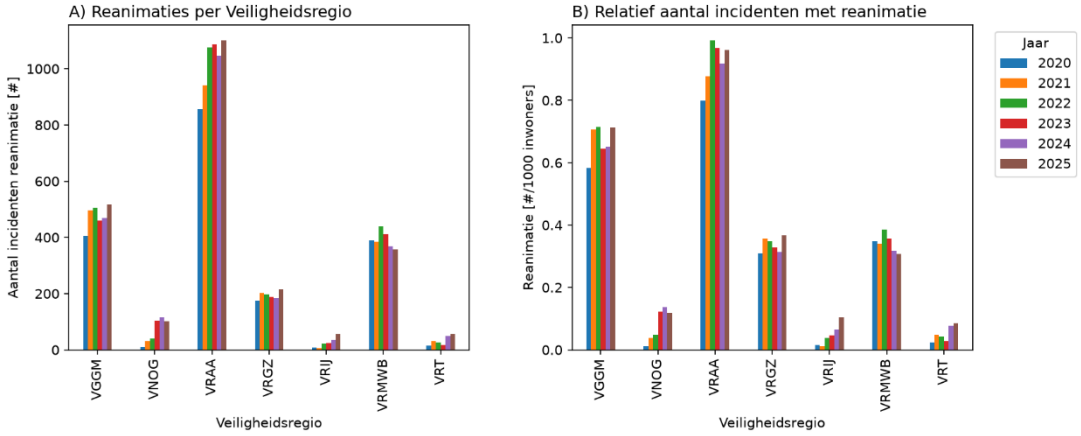
Het aantal gemelde incidenten met meldingsclassificatie automatisch alarm is weergegeven in Figuur 3.7A. In de figuur is een flinke afname in de automatische alarmen zichtbaar voor zowel VRAA als VRMWB, wat vermoedelijk met een gewijzigd beleid ten aanzien van deze meldingen te maken heeft. Figuur 3.7A laat ook vrij grote verschillen tussen de regio's zien. Dit zou verklaard kunnen worden door de aantallen verblijfsobjecten die automatische alarmen bevatten. Over het algemeen zullen automatische meldsystemen vooral gevonden worden in bedrijven, kantoren en instellingen. In Figuur 3.7B is het aantal automatische alarmen daarom geschaald naar de aantallen niet-woningen. Er is een opvallende piek bij VRAA te zien in het aantal automatische alarmen. De schaling maakt de aantallen meer vergelijkbaar tussen de regio's, maar kan de verschillen niet volledig verklaren.



Figuur 3.7. Het aantal gemelde incidenten met meldingsclassificatie automatisch alarm per VR en per jaar; (A) absolute aantallen, (B) aantallen per 1000 niet-woningen

3.1.9 Reanimaties

Het jaarlijkse aantal gemelde incidenten met meldingsclassificatie reanimatie staat weergegeven in Figuur 3.8A. De aantallen zijn ongeveer gelijk over de jaren, waarbij er een kleine toename is in de regio's VNOG, VRIJ en VRT. Er zijn wel grote verschillen tussen de regio's. Ook wanneer er geschaald wordt naar het aantal inwoners (Figuur 3.8B), zijn er grote verschillen in de relatieve aantallen reanimaties tussen de regio's. Dit heeft vermoedelijk te maken met het beleid in de regio voor wat betreft reanimaties. Niet in alle regio's wordt reanimatie namelijk opgepakt als brandweertaak (Dangermond en Broeren, 2025).

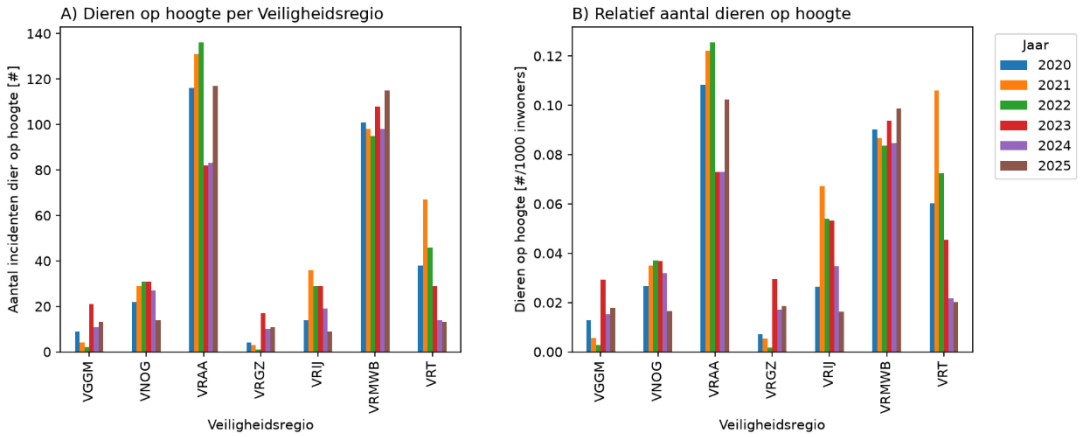


Figuur 3.8. Het aantal gemelde incidenten met meldingsclassificatie reanimatie per VR en per jaar; (A) absolute aantallen, (B) aantallen per 1000 inwoners

3.1.10 Dieren op hoogte

Het jaarlijkse aantal gemelde incidenten met meldingsclassificatie dieren – op hoogte staat weergegeven in Figuur 3.9A. Dit type incidentmeldingen betreft bijvoorbeeld katten in de boom. Deze aantallen zijn geschaald naar het aantal inwoners, waarbij is aangenomen dat het vooral huisdieren betreft en dat het percentage inwoners met huisdieren constant is over de regio's (zie Figuur 3.9B). Het aantal inwoners wordt dus als proxy gebruikt. Opvallend is dat het aantal dieren op hoogte groter is in VRAA en VRMBW, en dat VRT een afname laat zien. Mogelijk is het beleid van de regio's of de classificatie van meldingen met betrekking tot

uitrukken voor dieren op hoogte van invloed. In 2025 lijkt het aantal gemelde incidenten over dieren op hoogte wat lager en ongeveer gelijk te liggen in de regio's die vallen onder de meldkamer Oost-Nederland, namelijk de VGGM, VNOG, VRGZ, VRIJ en VRT.



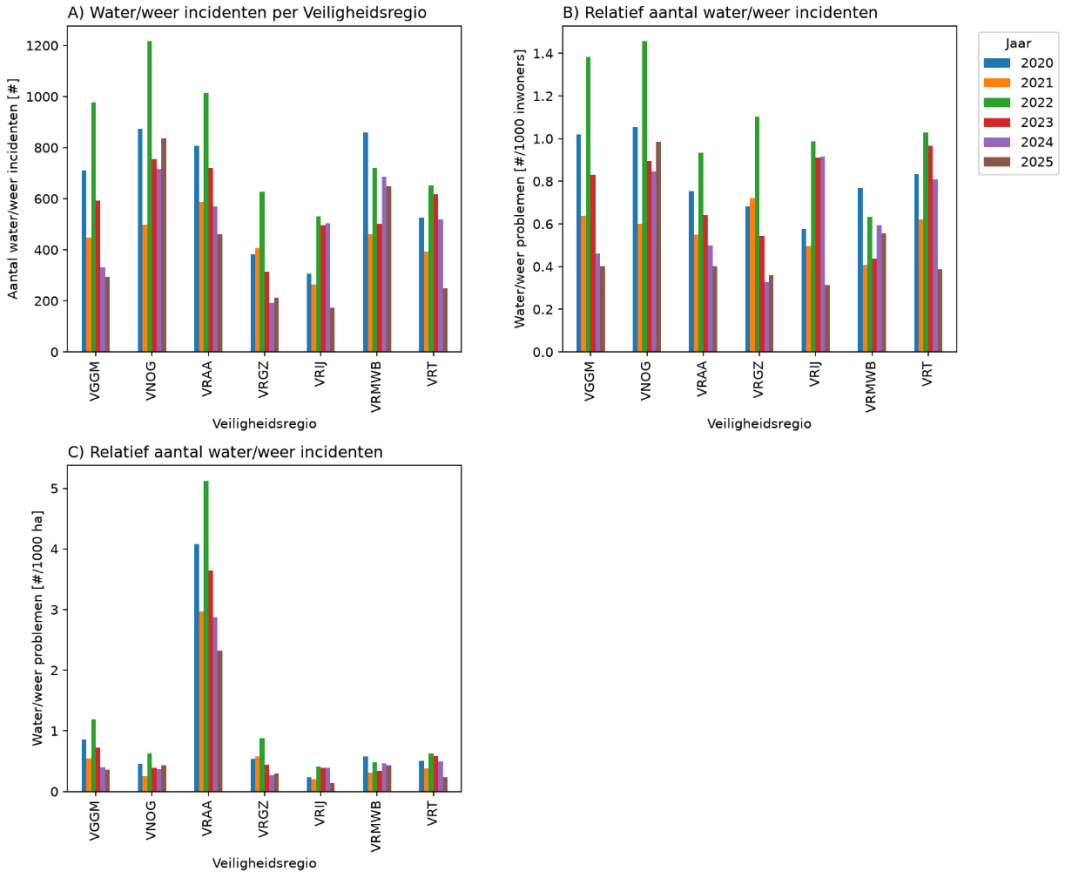
Figuur 3.9 Het aantal gemelde incidenten met meldingsclassificatie dier op hoogte per VR en per jaar; (A) absolute aantallen, (B) aantallen per 1000 inwoners

3.1.11 Water- en weerincidenten

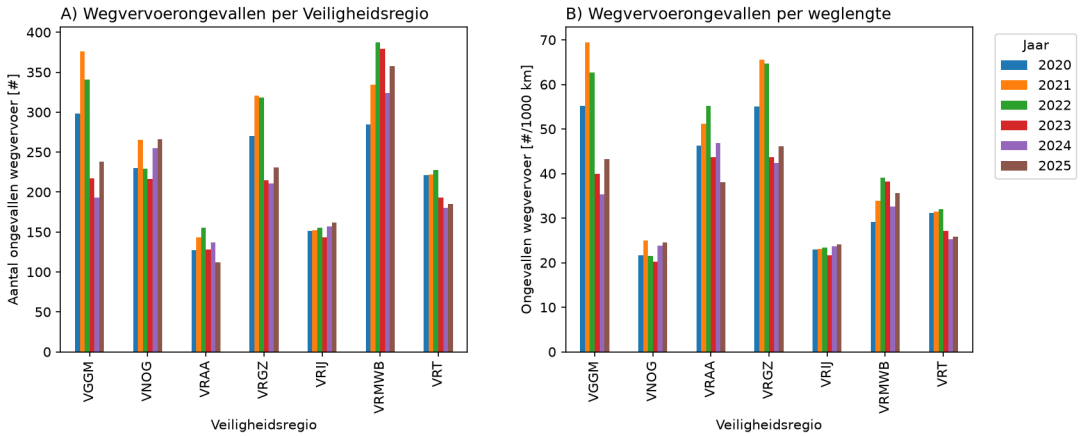
Figuur 3.10A laat het jaarlijkse aantal gemelde incidenten met meldingsclassificatie water- / weerproblemen zien, meestal veroorzaakt door storm of onweer. Naast verschillen tussen de regio's zijn er ook jaarlijkse verschillen in water- / weerincidenten. Zo is op 18 februari 2022 een zware storm ('Eunice') over Nederland getrokken, waarvoor een zeldzame code rood is uitgevaardigd (KNMI, 2022). Dit kan de piek in het aantal incidentmeldingen voor het jaar 2022 verklaren. De totale oppervlakte van natuurgebieden verschilt tussen regio's, maar wanneer het aantal gemelde incidenten wordt geschaald naar het aantal inwoners is deze min of meer constant over de regio's (zie Figuur 3.10B). Dit komt waarschijnlijk doordat schade in natuurgebieden, zoals omgewaaide bomen midden in een bos, geen hinder veroorzaken voor mensen en niet leiden tot een incidentmelding. In Figuur 3.10C worden de aantallen incidentmeldingen geschaald naar totaal landoppervlak weergegeven. Deze figuur laat zien dat VRAA veel hogere aantallen incidenten per oppervlak laat zien dan de andere regio's, waar de aantallen incidenten geschaald naar oppervlak ook min of meer gelijk zijn aan elkaar.

3.1.12 Ongevallen wegvervoer

Figuur 3.11A laat het jaarlijkse aantal gemelde incidenten met meldingsclassificatie ongeval wegvoertuig zien. Dit zijn voornamelijk verkeersongevallen. Met name de regio's VGGM en VRGZ laten een afname zien in de aantallen van 2022 naar 2023. Voor de overige regio's zijn de jaarlijkse aantallen min of meer constant. In Figuur 3.11B zijn de ongevallen wegvervoer geschaald naar de totale weglengte in de regio, omdat alleen bewegende voertuigen ongevallen kunnen veroorzaken en de weglengte wordt gebruikt als proxy voor aantallen bewegende voertuigen. De figuur laat een wat lager aantal zien voor de VNOG en VRIJ.



Figuur 3.10 Het aantal gemelde incidenten met meldingsclassificatie water- / weerproblemen per VR en per jaar; (A) absolute aantallen, (B) aantallen per 1000 inwoners en (C) aantallen per landoppervlak

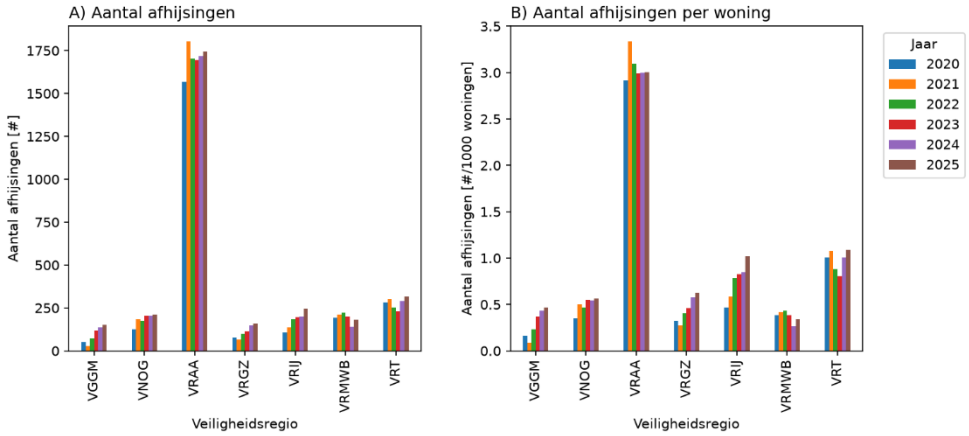


Figuur 3.11 Het aantal gemelde incidenten met meldingsclassificatie ongeval wegvervoer per VR en per jaar; (A) absolute aantallen, (B) aantallen per weglengte

3.1.13 Afhijsingen

Incidenten worden niet alleen gekenmerkt door de meldingsclassificatie. De centralist kan ook een aantal karakteristieken weergeven die extra informatie geven over het incident. Dit betreft bijvoorbeeld een ‘afhijsing’ waarbij de brandweer de ambulance assisteert bij het uit huis halen van een bewoner. Figuur 3.12A laat zien dat de incidenten met karakteristiek

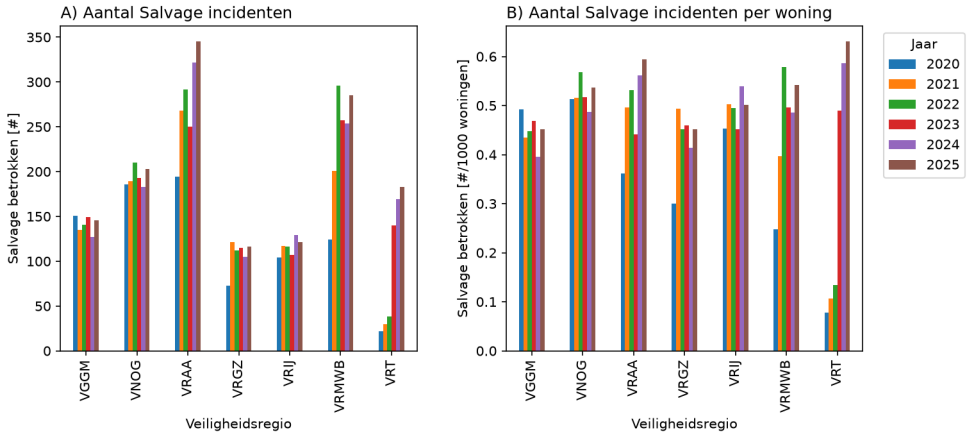
afhijsing ongeveer constant zijn over de jaren en veel meer plaats vinden in de regio VRAA, mogelijk vanwege grotere aantal gebouwen met meerdere woonlagen waar een lift ontbreekt. Er is geen openbare database beschikbaar met het aantal woonlagen en de aanwezigheid van een lift. Eventueel zouden er op basis van bouwjaar en hoogte van een pand uit de landelijke hoogtemetingen daarover wel aannames kunnen worden gemaakt, maar in dit onderzoek is er in Figuur 3.12B geschaald naar het aantal woningen. Ook dan is het aantal afhijsingen in VRAA veel groter dan de andere regio's. De regio's VGGM, VRGZ en VRIJ laten een toename in het aantal afhijsingen zien over de jaren.



Figuur 3.12 Het aantal gemelde incidenten met karakteristiekwaarde afhijsen voor de karakteristiek inzet brandweer algemeen ('Inz Br Alg') per VR en per jaar; (A) absolute aantallen, en (B) aantallen per 1000 woningen

3.1.14 Salvage

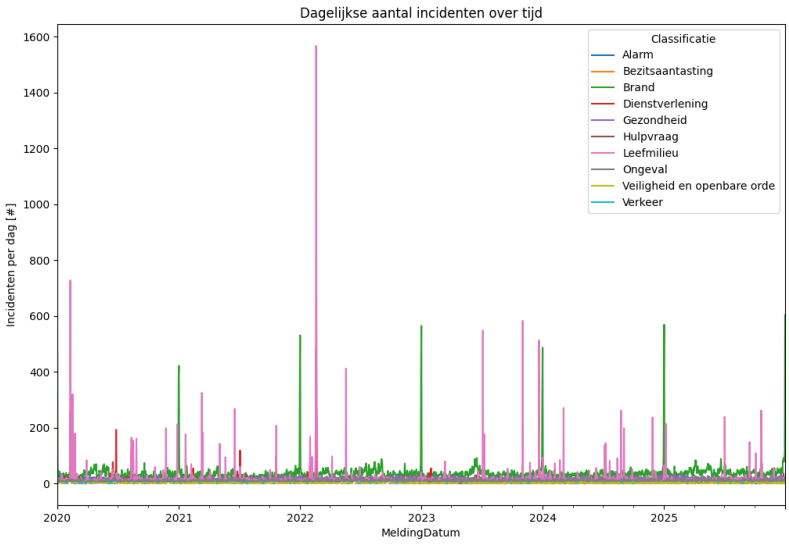
Bij een woningbrand kan ervoor gekozen worden om stichting Salvage in te schakelen. Analoog aan de vorige paragraaf kan de centralist dan een karakteristiek 'Instantie' aanmaken met als waarde 'salvage'. In Figuur 3.13A is het jaarlijkse aantal gemelde incidenten die de karakteristiekwaarde 'salvage' bevatten weergegeven. De figuur laat voor de meeste regio's een min of meer stabiel aantal incidenten zien. Enkel voor VRT is een opvallende toename in het aantal incidenten te zien van 2022 naar 2023. Dit komt door wijziging in registratie tussen meldkamer Twente en meldkamer Oost-Nederland (overgang maart 2023). Voorheen werd Salvage in Twente namelijk meestal niet met een karakteristiek geregistreerd. Er zijn ook verschillen in aantallen tussen regio's zichtbaar, wat vermoedelijk met het aantal woningbranden en woningen te maken heeft. Wanneer geschaald wordt naar het aantal woningen (zie Figuur 3.13B), dan is het aantal incidenten met karakteristiek-waarde 'salvage' tussen regio's ongeveer gelijk bij een waarde van 0.5 per 1000 woningen. Wanneer we dat vergelijken met het aantal woningbranden per woning (zie Figuur 3.4), zien we dat bij ongeveer twee derde van de woningbranden 'salvage' als karakteristiekwaarde is opgenomen. Salvage wordt standaard gealarmeerd bij middelbrand en grotere branden, die ongeveer 50% van het totaal aantal gemelde woningbranden per jaar uitmaken. Daarnaast kan Salvage ook worden ingezet bij kleinere branden, bijvoorbeeld wanneer sprake is van aanzienlijke rook-, roet- of waterschade (Stichting Salvage, 2026). Dit kan verklaren waarom Salvage bij ongeveer twee derde van de woningbranden als karakteristiekwaarde is geregistreerd.



Figuur 3.13 Het aantal gemelde incidenten met karakteristiekwaarde salvage voor de karakteristiek instantie per VR en per jaar; (A) absolute aantallen, en (B) aantallen per 1000 woningen

3.1.15 Gemelde incidenten over tijd

Er zijn opmerkelijke verschillen in het aantal dagelijkse gemelde incidenten over de tijd. Figuur 3.14 laat zien dat het totaal aantal incidenten per dag gewoonlijk onder de honderd ligt voor de betrokken regio's. Op sommige momenten kan het aantal gemelde incidenten echter sterk oplopen. Rondom de jaarwisseling zijn er zelfs tot meer dan duizend gemelde incidenten per dag. Daarnaast zijn er hoge pieken in de meldingsclassificatie leefmilieu; deze hebben te maken met storm- en onweer. De hoogste piek trad op tijdens storm Eunice op 18 februari 2022. De pieken met meldingsclassificatie Dienstverlening treden vooral in 2020, 2021 en 2022 op in VRMWB. Zo is er daar een hoge piek op 26 juni 2020 (zware bui met plaatselijk veel neerslag (KNMI, 2020)) en op 18 februari 2022 tijdens storm Eunice (KNMI, 2022)). De classificatie Dienstverlening werd destijds door VRMWB gebruikt in plaats van de meer gebruikelijke classificatie Leefmilieu.



Figuur 3.14 Het aantal dagelijkse incidenten per meldingsclassificatie

3.1.16 Conclusie

In dit hoofdstuk is gerapporteerd over een exploratieve data-analyse. Er zijn van tevoren geen hypotheses opgesteld; daarom zijn er ook geen statistische toetsen uitgevoerd. Het hoofdstuk is bedoeld om meer inzicht te geven in de beschikbare data en de kenmerken daarvan.

Er is inzichtelijk gemaakt dat VR's aanzienlijk van elkaar verschillen als het om regiokenmerken, zoals aantallen inwoners, weglengte, grondgebruik en aantallen woningen gaat. Hierdoor kunnen ook de aantallen en aard van de incidenten en de meldingsclassificaties van elkaar verschillen. Daarnaast zien we dat er toe- of afnames van specifieke meldingsclassificaties zijn over de tijd. Dit wordt meestal niet veroorzaakt door echte wijzingen in het voorkomen van deze incidenten, maar vaak door wijzigingen in registratie.

Om in toekomstig werk wel vergelijkingen tussen regio's in gemelde aantallen incidenten te kunnen maken, zou een dieper inzicht in de context van en verschillende processen bij de VR's en de betrokken meldkamers nodig zijn.

3.2 Kladblokkenmerken

3.2.1 Inleiding

Tijdens de incidentbestrijding communiceren de meldkamer en de hulpdiensten (brandweer, politie en ambulance) via het GMS. Naast velden zoals meldingsclassificatie en prioriteit bevat het GMS ook het kladblok. De centralist op de meldkamer gebruikt het kladblok om kenmerken van het incident, informatie rondom het incident en de gekozen bestrijding in op te slaan. Het is een belangrijk veld voor communicatie en bevat mogelijk waardevolle gegevens voor evaluatie en onderzoek achteraf.

De VR's gaan ervan uit dat het kladblok ook persoonsgegevens bevat en zijn daarom ook zeer terughoudend in het gebruik ervan voor bijvoorbeeld rapportage en onderzoek. Wanneer het kladblok wel gebruikt kan worden in onderzoek, kan dit mogelijk waardevolle nieuwe diepgaande kennis opleveren, wat de incidentbestrijding ten goede komt. Inzicht kan bijvoorbeeld bijdragen aan een betere voorbereiding of betere preventieadviezen.

Hoeveel persoonsgegevens werkelijk voorkomen in het kladblok en of deze regels goed te verwijderen zijn voordat data voor onderzoek beschikbaar worden gesteld is nog niet onderzocht. In deze analyse hebben we onderzocht of en hoe vaak persoonsgegevens voorkwamen in het kladblok en welke verwijderingsstappen nodig zijn om deze te verwijderen. Vervolgens hebben we onderzocht welke opschoningsstappen nodig zijn om het kladblok ook bruikbaar te maken voor rapportage en onderzoek.

3.2.2 De structuur van het kladblok

Het kladblok bestaat uit een tabel met veel rijen. Elke rij bevat gestructureerde velden bestaande uit een incident-id, een kladblokregel-id, een volgnummer en een tijdstip. Elke rij heeft ook een kladblokregel. Dit is een ongestructureerd veld waarin communicatie over en de bestrijding van het incident zijn opgenomen. Meestal past de input van de centralist in

één kladblokregel. Soms is de input te lang en wordt de tekst over meerdere rijen verspreid, elk met hetzelfde kladblokregel-id maar met een oplopend volgnummer. Het tijdstip is dan wel hetzelfde. Zie Tabel 3.2 voor een fictief voorbeeld.

Tabel 3.2 Fictief voorbeeld van structuur van kladbloktabel

INCIDENT_ID	KLADBLOK_REGEL_ID	VOLG_NR_KLADBLOK_REGEL	T_IND_DISC_KLADBLOK_REGEL	TIJDSTIP	INHOUD_KLADBLOK_REGEL
1	8	2	PB-	12:01	Aanvang van incident
1	9	2	-B-	12:03	Er is een grote brand uitgebroken
1	10	2	-B-	12:04	Vlammen zichtbaar, forse
1	10	3	-B-	12:04	rookontwikkeling, melder wacht op
1	10	4	-B-	12:04	brandweer
2	78	2	-BA	13:05	Ongeluk met beklemming

In dit fictieve voorbeeld staan twee incidenten, met incident-id 1 en 2. Incident 1 bevat 3 ‘regels’ (zie kolom KLADBLOK_REGEL_ID). De derde regel (regel-id 10) is ingevoerd op tijdstip 12:04 en is te lang voor één rij. Daarom is deze regel opgesplitst over meerdere rijen met oplopende volgnummers. Voor de analyse in deze paragraaf worden de opgesplitste regels weer opnieuw samengevoegd tot één regel. In deze paragraaf rapporteren we over aantallen incidenten en aantallen kladblokregels. In het fictieve voorbeeld hierboven spreken we dan over twee incidenten met in totaal vier regels.

De tabel bevat ook informatie over de hulpdienst (brandweer (B), politie (P), ambulance (A) of combinaties daarvan) waarvoor de regel bestemd is. Binnen één incident kunnen de verschillende regels voor verschillende (combinaties van) hulpdiensten bestemd zijn.

3.2.3 Opschonen van het kladblok

Voor alle gemelde incidenten (N=245061) uit paragraaf 3.1.4 is de bijbehorende kladbloktekst uit de database geladen, waarbij alleen regels die mede bedoeld zijn voor de discipline ‘brandweer’ zijn geselecteerd. Dit kunnen regels zijn die alleen bedoeld zijn voor de brandweer en ook regels die voor brandweer en een andere discipline samen bestemd zijn. Voor de jaren 2020-2025 resulteert dit een totaal van ruim twee miljoen (2062412) kladblokregels.

De kladbloktekst kan persoonlijke informatie bevatten. Vaak bevatten deze regels een van de termen ‘RTIC’, ‘BRP’, ‘Bluespot’, ‘-rtici’, of ‘BSN’. Dit zijn indicatoren voor de externe systemen die gebruikt worden om persoonlijke informatie aan het kladblok toe te voegen van burgers die bij het incident betrokken zijn. De dataset bevat 3001 regels (0,15 %) met ten minste een van deze termen. Deze regels zijn verwijderd.

Om te onderzoeken of er nog persoonlijke data waren overgebleven, is de dataset gecontroleerd op de aanwezigheid van burgerservicenummers (BSN). Het BSN bestaat uit negen cijfers en voldoet aan de 11-proef (Overheid Wettenbank, 2009). De dataset bleek 80 regels (0.0039 %) met een dergelijk getal te bevatten. Als een getal aan de 11-proef voldoet, wil dat nog niet zeggen dat het ook een BSN is; een willekeurig getal van negen cijfers voldoet namelijk een op de elf keer aan de 11-proef. Het aantal regels met een mogelijke BSN ligt erg laag. Daarom is geconcludeerd, in afstemming met de Functionarissen Gegevensbescherming van de deelnemende partijen, dat de resterende hoeveelheid persoonlijke informatie in het kladblok verwaarloosbaar klein is.

Deze procedure heeft geresulteerd in de incidentaantallen zoals weergegeven in Tabel 3.3. De aantallen liggen wat lager dan de aantallen uit Tabel 3.1: voor 5359 incidenten (ongeveer 2 %) is namelijk geen kladbloktekst beschikbaar.[5]

In 51 gemelde incidenten is er sprake van meer dan tien herhalingen van exact dezelfde kladblokregel. Dit is veroorzaakt door een fout in de automatische systemen.[6] In een enkel geval was er zelfs sprake van eenzelfde kladblok regel die een uur lang elke paar seconden werd toegevoegd (1854 keer). Een dergelijk hoog aantal herhalingen van dezelfde tekst verstoort de analyses. Daarom zijn deze gemelde incidenten verwijderd.

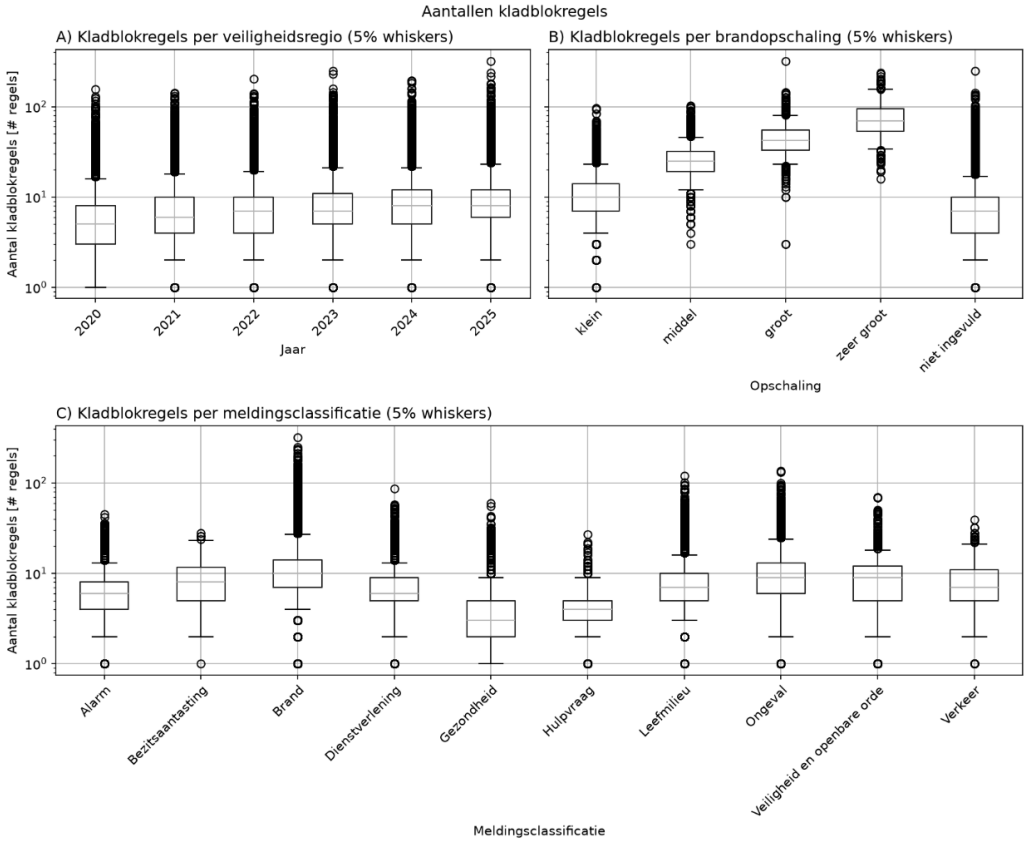
Tabel 3.3 Aantallen gemelde incidenten met kladbloktekst per VR en jaar

VR	2020	2021	2022	2023	2024	2025	Totaal per regio (%)
VGGM	4624	4497	5505	4636	4588	4931	**28781 (12%)**
VNOG	4685	4217	5386	4679	4687	5454	**29108 (12%)**
VRAA	11714	11880	13093	11655	12006	12073	**72421 (30%)**
VRGZ	4250	4036	4485	3718	3844	4287	**24620 (10%)**
VRIJ	2827	2744	3357	3029	3050	3116	**18123 (8%)**
VRMWB	4705	7354	8874	8070	7041	7791	**43835 (18%)**
VRT	4070	3800	4289	3577	3480	3598	**22814 (10%)**
Totaal per jaar	**36875**	**38528**	**44989**	**39364**	**38696**	**41250**	**239702 (100%)**

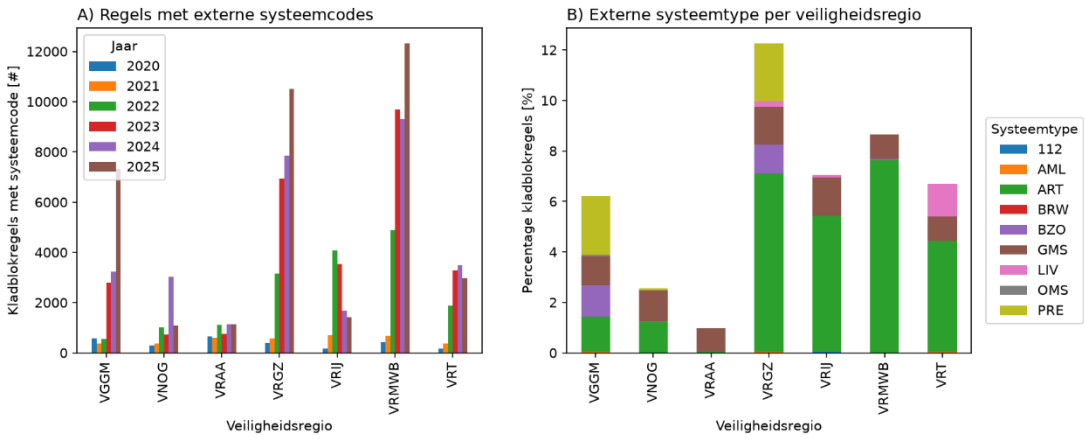
Het aantal kladblokregels varieert aanzienlijk, afhankelijk van het type en de grootte van het gemelde incident. In Figuur 3.15 is zichtbaar dat het aantal kladblokregels over het algemeen onder de tien ligt. Over de jaren heen lijkt het aantal kladblokregels geleidelijk wat op te lopen (zie Figuur 3.15A). Voor incidenttypen als brand en ongeval ligt het aantal regels voor de brandweer wat hoger dan voor incidenten met meldingsclassificatie gezondheid en hulpvraag waarvan de meeste regels voor de ambulance bestemd zullen zijn (zie Figuur 3.15C). Als er sprake is van brand, dan is het aantal regels groter naar mate de opschaling groter is (zie Figuur 3.15B).

[5] Vooral voor VRMWB in 2020 lijken er kladblokdata te ontbreken; hier is het getal lager dan verwacht kan worden op basis van de volgende jaren.
[6] Persoonlijke communicatie Eric Klein Goldewijk (d.d. 01-04-2026).

Diverse systemen kunnen automatisch regels toevoegen in het kladblok bij een incident. Figuur 3.16A laat zien dat het gebruik van externe systemen over de jaren toe lijkt te nemen. De fractie van kladblokregels afkomstig van automatische systemen is echter redelijk beperkt. Figuur 3.16B laat zien dat tot 12 % van de regels afkomstig is van automatische systemen. De figuur laat ook zien dat de gebruikte systemen verschillen per regio, evenals de hoeveelheid regels die deze systemen over de tijd toevoegen.



Figuur 3.15. Het aantal kladblokregels op een logaritmische schaal ten opzichte van (A) het jaar, (B) de brandopschaling en (C) de meldingsclassificatie



Figuur 3.16 Het gebruik van externe systemen in het kladblok voor de betrokken regio's in (A) het aantal kladblokregels per jaar en (B) percentage kladblokregels per type extern systeem voor de jaren 2020-2025

3.2.4 Conclusie

De analyse van het kladblok heeft laten zien dat de hoeveelheid persoonsgegevens in de kladblokregels van de brandweer erg laag is. Omdat de persoonsgegevens vaak in een gestructureerde vorm voorkomen, zijn deze met een aantal relatief simpele stappen te verwijderen. Wanneer deze stappen worden gevolgd zijn er geen belemmeringen om de gegevens uit het kladblok te gebruiken in rapportages en onderzoek. Er dient natuurlijk wel op een veilige en verantwoorde manier te worden omgegaan met de data.

3.3 Karakteristieken

3.3.1 Inleiding

Het GMS bevat een groot aantal karakteristieken dat informatie geeft over onder andere de aard van de melding, de betrokken hulpdiensten, de locatie, het tijdsverloop en de inzet van eenheden. Zodra een melding binnenkomt, registreert de centralist informatie die door de melder wordt verstrekt. Hierbij kunnen met behulp van karakteristieken gegevens worden vastgelegd over het incident, bijvoorbeeld het aantal gewonden, de soort woning of als er opschaling nodig is. Daarnaast kunnen gedurende het incident automatisch of handmatig aanvullende karakteristieken worden toegevoegd. Deze karakteristieken maken het dus mogelijk om meldingen verder te classificeren en daarmee operationele processen te ondersteunen. In dit hoofdstuk wordt verder ingegaan op de momenteel gebruikte karakteristieken in Oost-Nederland.

3.3.2 Methode

Voor de beschrijvende analyse is gebruikgemaakt van alle incidenten die zijn vermeld in GMS-data van de periode 2024 en 2025 in Oost-Nederland (VRT, VRIJ, VRNOG, VGGM en VRGZ). In maart 2023 zijn de meldkamers in Arnhem, Hengelo en Apeldoorn gemigreerd naar de nieuwe Meldkamer Oost-Nederland (Brandweer Nederland, 2023). De analyse is beperkt tot deze vijf VR's binnen Oost-Nederland, omdat er in deze regio's sinds de vorming van de gezamenlijke meldkamer sprake is van een relatief geharmoniseerde registratie van incidentgegevens. Tevens zijn voor deze analyse alleen de jaren 2024 en 2025 gekozen, om beïnvloeding van de gegevens door veranderingen in het systeem te voorkomen.

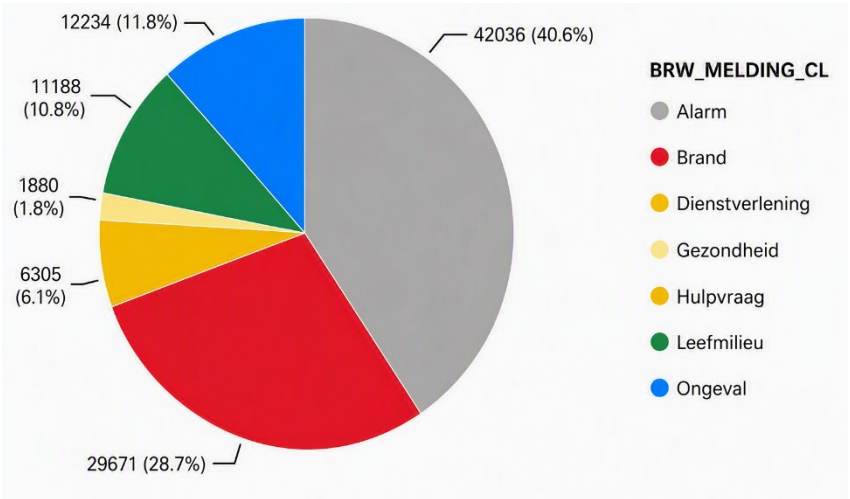
Voor dit onderzoek is gefilterd op de classificaties alarm, brand, dienstverlening, gezondheid, leefmilieu en ongeval. Vergeleken met andere classificaties, zijn bij deze classificaties de meeste karakteristieken genoteerd. De beschrijvende analyses en visualisering van resultaten zijn uitgevoerd in PowerBI.

3.3.3 Resultaten

In totaal telt de dataset 98.636 incidenten over de jaren 2024 (n= 48.787) en 2025 (n=49.849) (Tabel 3.4). Onder deze incidenten zijn in totaal 55.030 karakteristieken gerapporteerd, wat betekent dat ten minste 45 % van de incidenten geen karakteristiek heeft. Incidenten kunnen ook meer dan één karakteristiek hebben. Van de incidenten met karakteristieken, betreft het merendeel de meldingsclassificaties Alarm (40,6 %) en Brand (28,7 %) (Figuur 3.17).

Tabel 3.4 Aantal geregistreerde incidenten en karakteristieken per jaar en per regio

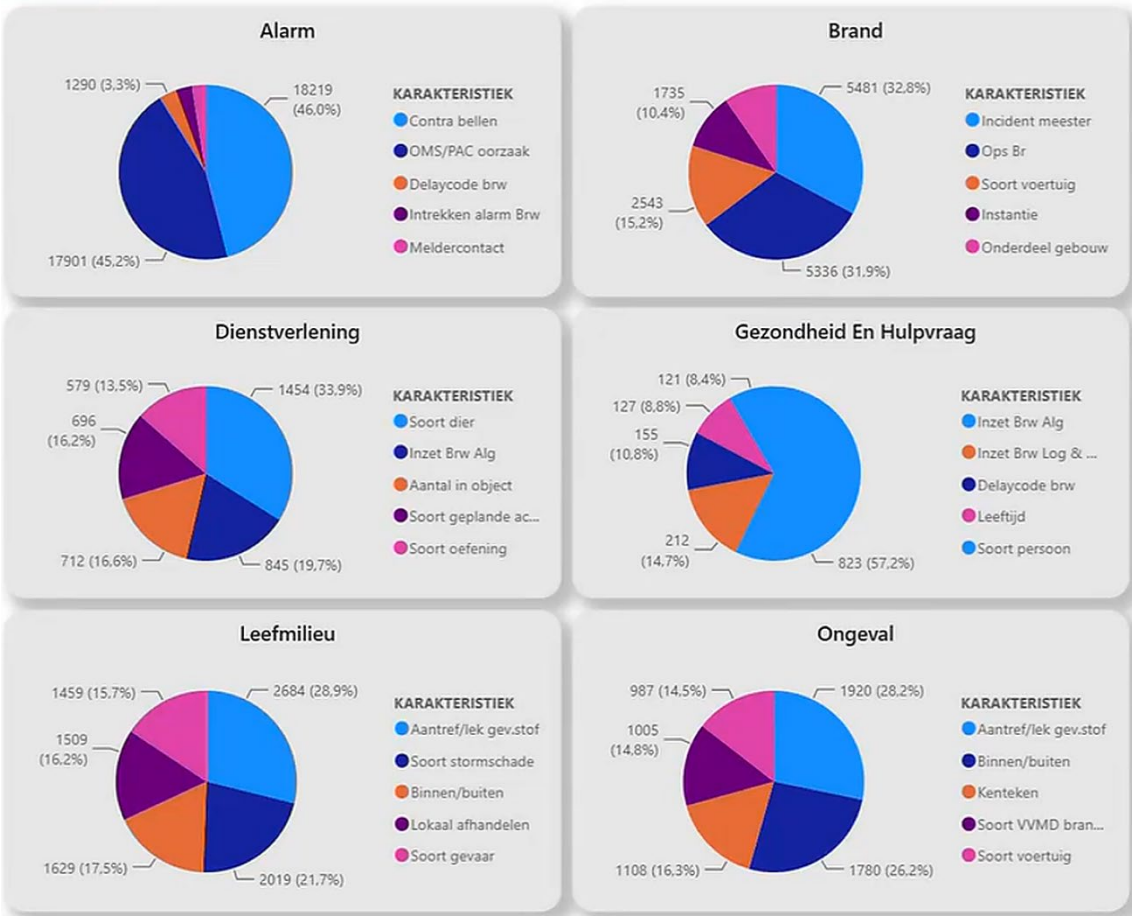
Jaar	Regio	Aantal Incidenten	Aantal karakteris-tieken	% incidenten met karakteristieken
2024		**48.787**	**27.023**	**55,40%**
	VR IJsselland	7761	4304	55,50%
	VR Twente	9401	5171	55,00%
	VR Noord- en Oost-Gelderland	12.995	7593	58,40%
	VR Gelderland-Midden	9848	4942	50,20%
	VR Gelderland-Zuid	8782	5013	57,10%
2025		**49.849**	**28.007**	**56,20%**
	VR IJsselland	7747	4196	54,20%
	VR Twente	9067	5034	55,50%
	VR Noord- en Oost-Gelderland	13.542	8152	60,20%
	VR Gelderland-Midden	10.244	5177	50,50%
	VR Gelderland-Zuid	9249	5448	58,90%
Totaal		**98.636**	**55.030**	**55,80%**



Figuur 3.17 Taartdiagram van het aantal gebruikte karakteristieken bij meldingsclassificaties

Bij de overige classificaties zijn aanzienlijk minder vaak karakteristieken gerapporteerd, waarbij Gezondheid met 1,8 % het kleinste aandeel heeft. In totaal zijn 197 unieke karakteristieken geïdentificeerd in de dataset.

De karakteristieken Contra bellen[7] (n=18684) en OMS/PAC[8] (n=18072) vallen onder de meldingsclassificatie Alarm, en komen veruit het vaakste voor. Daarna zijn de karakteristieken Incident Meester[9] (n=6120), Ops Br[10] (n= 5357) en Inzet Brw Alg[11] (n=1728) het meeste gebruikt. Als er per meldingsclassificatie wordt gekeken, krijgt elke meldingsclassificatie een andere top vijf van meestgebruikte karakteristieken (Figuur 3.18). Karakteristieken die het minste worden gebruikt, zijn vaak karakteristieken die horen bij de discipline ambulancezorg of politie. Deze worden amper door een brandweercentralist gebruikt. Voorbeelden hiervan zijn de karakteristieken Overdosis, Hoofdpijn en Psychiatrisch, die maar één keer vermeld zijn in de data.



Figuur 3.18 Top vijf van meest gebruikte karakteristieken per meldingsclassificatie

3.3.4 Conclusie

Uit de analyse van 95.028 incidenten in Oost-Nederland in 2024 en 2025 blijkt dat karakteristieken binnen GMS een belangrijke bron van aanvullende informatie kunnen vormen over incidenten en de inzet van hulpdiensten. Tegelijkertijd laat de analyse zien dat niet bij alle incidenten karakteristieken gebruikt worden: bij ten minste 45 % van de incidenten is geen karakteristiek geregistreerd. Dit wijst erop dat karakteristieken weliswaar waardevolle informatie bevatten, maar dat de beschikbaarheid en toepassing ervan afhankelijk zijn van de registratiepraktijk.

[7] Contra bellen: verificatie van automatische alarmen.
[8] OMS/PAC: systemen voor het automatisch doorsturen van meldingen.
[9] Incident Meester: sein voor situatie onder controle.
[10] Ops Br: opschaling brand.
[11] Inzet Brw Alg: inzet brandweer algemeen; wordt gebruikt voor algemene hulpverlening of assistentie van de brandweer.

De resultaten tonen tevens aan dat een beperkt aantal karakteristieken door de brandweer wordt gebruikt. Met name de systeemkarakteristieken OMS/PAC en Contra bellen komen zeer vaak voor. Deze karakteristieken worden grotendeels automatisch toegevoegd en zeggen relatief weinig over de inhoudelijke kenmerken van een incident. Voor vervolgonderzoek kan het daarom waardevol zijn om onderscheid te maken tussen systeem-, proces- en incidentkarakteristieken. Hierdoor kan een beter beeld worden gevormd van de karakteristieken die daadwerkelijk aanvullende informatie geven over de aard van een incident.

GMS bevat ook karakteristieken die voornamelijk worden gebruikt door politie of ambulancezorg. Het beperkte gebruik van sommige karakteristieken hoeft niet te betekenen dat deze weinig relevant zijn, maar kan samenhangen met de focus van de voorgaande analyse op brandweerincidenten. Daarnaast zijn recent wijzigingen doorgevoerd in de kladblokregels van politie en ambulancezorg. Dergelijke veranderingen kunnen invloed hebben op het toekomstige gebruik van karakteristieken en daarmee op de vergelijkbaarheid van analyses in de tijd.

Samenvattend vormen karakteristieken een waardevolle, maar nog niet optimaal benutte informatiebron. Verdere analyse is nodig om inzicht te krijgen in eventueel aanwezige patronen in het gebruik van karakteristieken. Verdere standaardisatie van registratie, aandacht voor datakwaliteit en onderzoek naar verschillen tussen centralisten en/of meldkamers kunnen ook bijdragen aan een effectiever gebruik van deze gegevens.

3.4 Uniformiteit van karakteristiekgebruik tussen VR’s

3.4.1 Inleiding

In deze paragraaf wordt onderzocht of er verschillen zijn tussen VR's als het gaat om het gebruik van karakteristieken. Hiervoor is onderzocht in hoeverre op basis van de geregistreerde karakteristieken in GMS de bijbehorende VR voorspeld kan worden. Wanneer er sprake is van voldoende uniformiteit in registratie en werkwijze tussen VR’s, zouden het gebruik en de toepassing van karakteristieken grotendeels vergelijkbaar moeten zijn, wat mogelijkheden zou kunnen bieden voor het uitvoeren van analyses op landelijk niveau. Wanneer regio’s daarentegen goed te onderscheiden zijn, kan dit duiden op verschillen in registratie van de karakteristieken of in werkprocessen. Het doel van dit onderzoek is om inzicht te krijgen in het gebruik van karakteristieken door VR's en verschillen ertussen inzichtelijk te maken. De onderzoeksvraag luidt: zijn de karakteristiekvelden van brandmeldingen van de VR's voldoende uniform of is het mogelijk om op basis van deze velden de VR's te herkennen?

3.4.2 Methode

Data

Voor deze analyse zijn incident- en karakteristiekendata gebruikt van alle zeven regio’s uit de periode 2024-2025. Vóór die periode vonden er namelijk wijzigingen in registratiesystemen plaats, waarvan we willen voorkomen dat ze de resultaten te veel beïnvloeden. Vervolgens zijn de data gefilterd op incidenten binnen de meldingsclassificatie Brand. Brandincidenten vormen een grote en relatief uniforme categorie, waardoor eventuele regionale verschillen in het gebruik van karakteristieken beter zichtbaar kunnen worden. Ten slotte zijn karakteristieken die minder dan tien keer voorkwamen in de dataset verwijderd,

om ruis te voorkomen. In Tabel 3.5 zijn alle toegepaste filters en uiteindelijke aantallen per model weergeven.

Tabel 3.5 Toegepaste filters en aantallen data

	Toegepaste filters	Totaal aantal unieke karakteristieken	Totaal aantal unieke incidenten	Totaal aantal observaties*
	Originele dataset	**287**	**219526**	**769803**
1	Verwijderen incidenten geregistreerd in 2026 (n=4)	285	219522	269758
2	Filter: 2024 en 2025	247	72345	281314
3	Filter: Brand	189	26570	104173
4	Filter: karakteristiek komt ≥10 keer voor	112	26570	104173
	Model A	**112**	**26570**	**104173**
5	Toevoeging: 30 dummy-variabelen met combinatie van karakteristieken en meestvoorkomende waarden	142	26570	104173
	Model B	**142**	**26570**	**104173**

* Een incident kan meerdere karakteristieken bevatten; daarom is er een extra kolom dat het totaal aantal karakteristieken van alle incidenten weergeeft.

Data-analyse

Voor het beantwoorden van de onderzoeksvraag zijn twee modellen gebruikt. Model A heeft uitsluitend de aanwezigheid van karakteristieken als voorspellers gebruikt. In totaal bleven er 112 karakteristieken over na filtering. Deze variabelen zijn omgezet naar dummyvariabelen. Model B bevatte dezelfde 112 karakteristieken als Model A, aangevuld met variabelen met informatie over veelvoorkomende combinaties van karakteristieken met hun karakteristiek-waarde. Combinaties die minimaal 500 keer voorkwamen in de dataset zijn opgenomen als dummyvariabele in Model B. Dit resulteerde in 30 extra variabelen, waaronder bijvoorbeeld '*Ops Br: klein'* en '*Incident meester: ja'*.

Voor beide modellen is gebruikgemaakt van een Random Forest met 100 trees. De afhankelijke variabele was de VR en de onafhankelijke variabelen bestonden uit de eerdergenoemde dummyvariabelen. Omdat het aantal registraties per VR niet gelijk verdeeld was, zijn 'weighted classes' toegevoegd aan de modellen (Tabel 3.6). Hiermee is voorkomen dat regio's met veel incidenten een onevenredig grote invloed zouden hebben op het model.

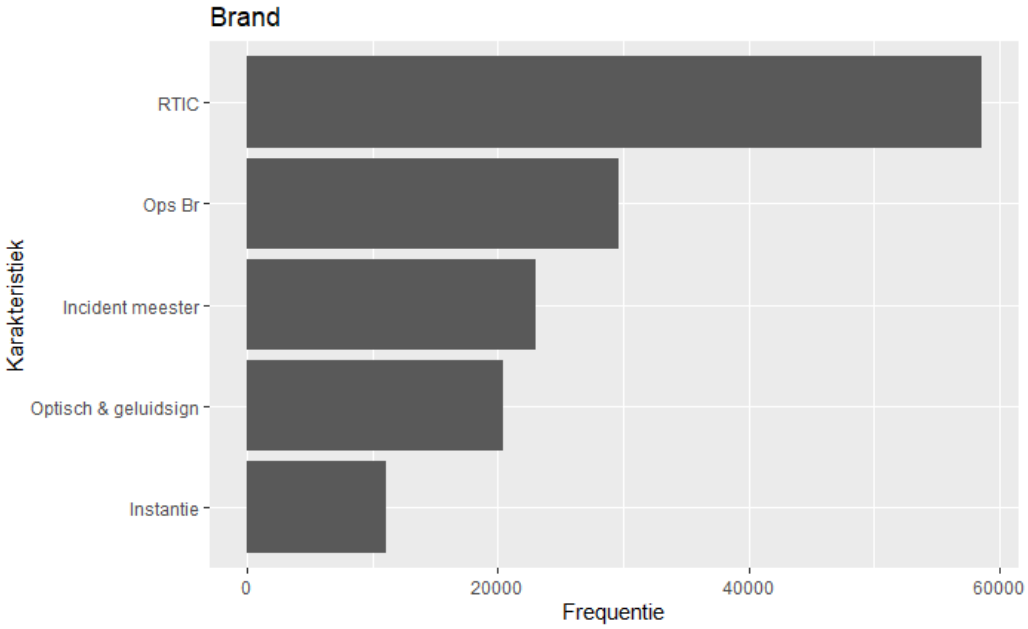
Tabel 3.6 Gewichten per VR

Regio	Aantal observaties	Weight
VGGM	11457	1.2989314
VNOG	12354	1.2046185
VRAA	25012	0.5949887
VRGZ	10236	1.4538743
VRIJ	7589	1.9609774
VRMWB	28459	0.5229227
VRT	9066	1.6415020

Aan de hand van de accuratesse (nauwkeurigheid) is bepaald in hoeverre het model de juiste regio wist te voorspellen. De importance van variabelen is bepaald aan de hand van Mean Decrease Gini (MDG), waarbij een hogere mean betekende dat de variabele een grotere invloed had op de voorspellingen van het model. De resultaten zijn gevisualiseerd in een confusion matrix. De analyses zijn uitgevoerd in R v4.6.0.

3.4.3 Resultaten

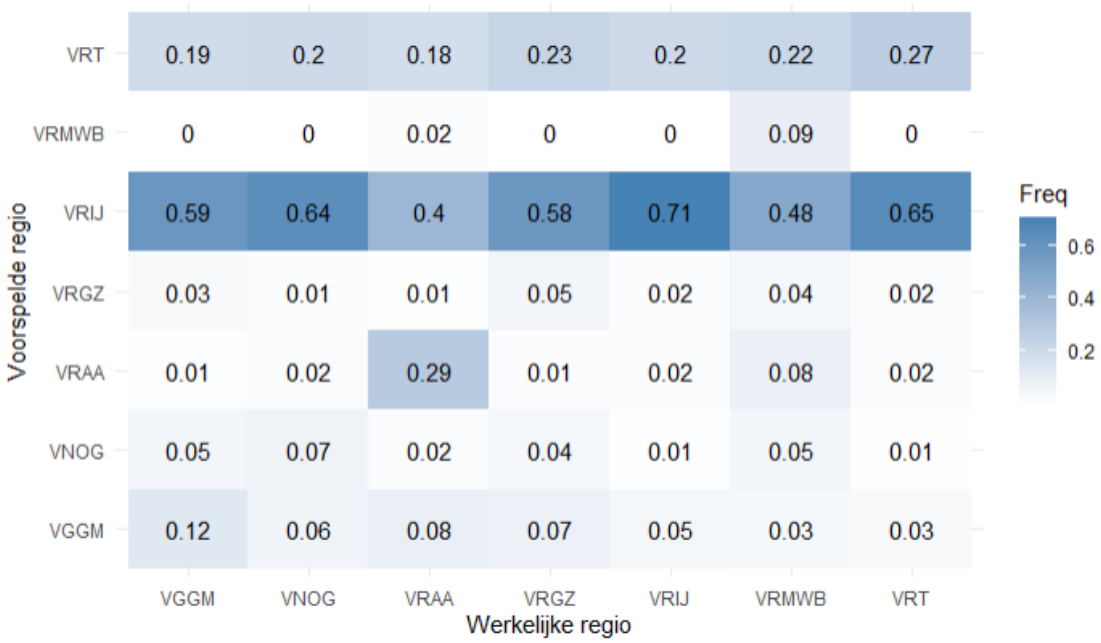
Binnen de meldingsclassificatie Brand bleek de karakteristiek RTIC (Real Time Intelligence Center) veruit het vaakst geregistreerd te worden in 2024-2025, met bijna 60.000 registraties (Figuur 3.19). Deze karakteristiek wordt vaak vastgelegd wanneer de politie bij een incident wordt betrokken.



Figuur 3.19 Top 5 meestvoorkomende karakteristieken binnen de meldingsclassificatie Brand

Model A
Model A behaalde een accuratesse van 19,6 %. Dit betekent dat het model in ongeveer één op de vijf gevallen de juiste VR voorspelde. Gezien het feit dat het model onderscheid maakte tussen zeven VR's, ligt een willekeurige voorspelling (random guess) rond de 14 % (100 / 7 = 14.2). Model A presteerde dus slechts een klein beetje beter dan als er gegokt zou worden. Dit resultaat suggereert dat de aanwezigheid van karakteristieken op zichzelf weinig onderscheidend vermogen heeft voor het herkennen van regio's. Dat zou erop kunnen wijzen dat regio's grotendeels dezelfde karakteristieken gebruiken, wat past bij de verwachting van een zekere mate van uniformiteit in registratie.

De confusion matrix van de resultaten van model A laat een duidelijke classificatiebias richting VRIJ zien (Figuur 3.20). Voor alle werkelijke regio's werd tussen de 40 % en 71 % van de incidenten geclassificeerd als VRIJ. Hierdoor bleven de percentages op de diagonaal relatief laag, wat duidt op een beperkt vermogen om regio's van elkaar te onderscheiden. Alleen voor VRIJ zelf was sprake van een redelijk herkenningsvermogen: 71 % van de incidenten uit deze regio werd correct geclassificeerd. Voor de overige regio's bleef dit beperkt. De resultaten laten daarmee zien dat het gebruik van alleen karakteristieknamen onvoldoende is om VR's betrouwbaar van elkaar te onderscheiden. Dit betekent dat VR's op basis van alleen de karakteristieken een hoge mate van uniformiteit lijken te vertonen.



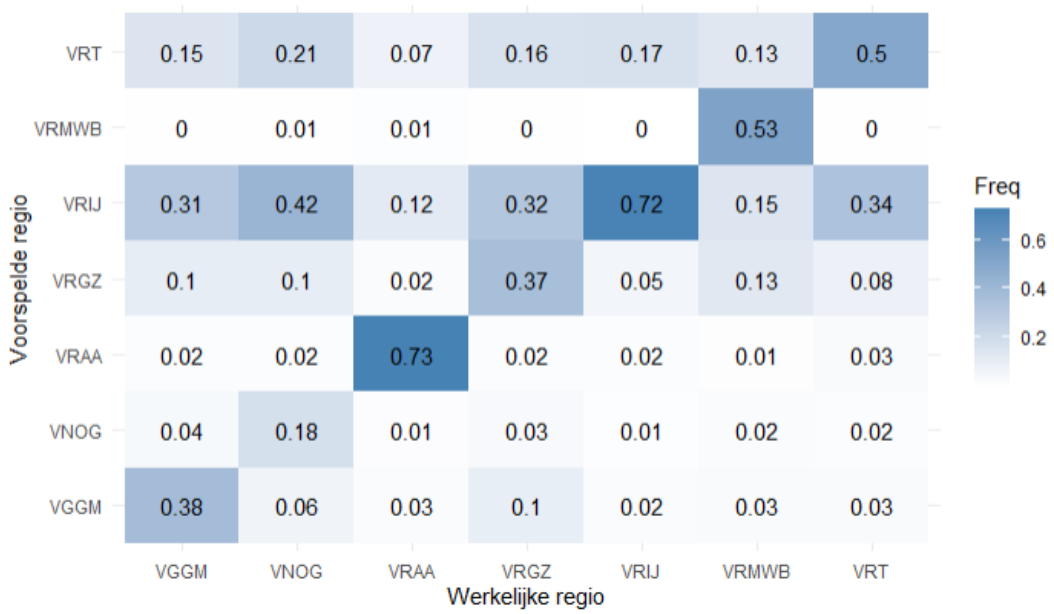
Figuur 3.20 Confusion matrix van Model A: Voorspelling van de VR op basis van karakteristieken bij brandincidenten

Hoewel de algehele modelprestatie beperkt was, waren er een aantal karakteristieken die relatief belangrijk voor de voorspelling waren. De drie meest voorspellende karakteristieken voor model A zijn *Soort geplande actie*, *Betreft* en *Ops HV*, met respectievelijk een MDG van 303, 250 en 238.

Model B
In Model B waren naast de 112 unieke karakteristieken ook 30 variabelen opgenomen die veelvoorkomende combinaties van karakteristieknamen en karakteristiekwaarden representeerden. Deze uitbreiding leidde tot een duidelijke verbetering van het model. Model B

behaalde een accuratesse van 51 %, waarmee het VR's aanzienlijk beter kon onderscheiden dan Model A. De drie meest voorspellende kenmerken waren: *Inzet Brw Log & OnS: arbeidshygiene (*MDG= 1922), *Soort geplande actie: stand by* (MDG = 1130) en *Inzet Pol algemeen: OpCo* (MDG = 931).

De prestaties verschilden tussen de regio's (Figuur 3.21). Met name VRAA (73 %) en VRIJ (72 %) werden relatief vaak correct geclassificeerd. De regio's VNOG (18 %), VRGZ (37 %) en VGGM (38 %) bleken wat minder goed op basis van karakteristieken van de overige regio's te onderscheiden. Incidenten uit deze regio's werden relatief vaak als VRIJ geclassificeerd. Deze vijf regio's (VRIJ, VGGM, VRGZ, VNOG en VRT) zijn dan ook aangesloten bij dezelfde meldkamer (Oost-Nederland), wat leidt tot uniformiteit. VRAA en VRMWB zijn juist elk bij een andere meldkamer aangesloten. Deze resultaten suggereren dat de karakteristieken van VRAA, VRIJ en in mindere mate VRMWB sterker onderscheidend waren, terwijl de kenmerken van de overige regio's meer overlap vertoonden.



Figuur 3.21 Confusion matrix van Model B: Voorspelling van de VR op basis van karakteristieken en meestvoorkomende karakteristiekwaarden bij brandincidenten

3.4.4 Conclusie

De resultaten laten zien dat het gebruik van karakteristieken goed overeenkomt tussen regio's, omdat de karakteristieken alleen slechts een beperkt onderscheidend vermogen hebben voor het voorspellen van VR's. Model A, dat uitsluitend gebruikmaakt van karakteristieknamen, presteert slechts beperkt beter dan toeval en kent een sterke neiging om incidenten als VRIJ te classificeren. Wanneer naast de karakteristieknamen ook de bijbehorende karakteristiekwaarden worden meegenomen, verbetert de modelprestatie aanzienlijk. De nauwkeurigheid stijgt van bijna 20 % naar 51 % en verschillende regio's worden duidelijk beter onderscheiden. Regio's die binnen dezelfde meldkamer opereren, zijn minder goed van elkaar te onderscheiden, wat de uniformiteit binnen een meldkamer onderstreept. Samenvattend lijkt het gebruik van karakteristieken dus niet zo zeer te verschillen tussen regio's, maar de additionele informatie gekoppeld aan de karakteristieken wel.

3.5 Incidentverificatie

3.5.1 Inleiding

De kwaliteit en betrouwbaarheid van GMS-gegevens zijn afhankelijk van de informatie die tijdens de melding wordt geregistreerd. Deze melding kan afwijken van de situatie zoals die werkelijk is. Een aanvullende incidentvragenlijst, die wordt ingevuld na afloop van een incident, kan meer inzicht bieden in de volledigheid en juistheid van de geregistreerde incidentkenmerken. Daarom werd hier als hoofdvraag onderzocht in hoeverre incident-informatie van GMS geverifieerd kan worden met data uit een aanvullende incidentvragen-lijst. Bijbehorende deelvragen waren 1) of de status in GMS klopt met de incidentregistratie, 2) of de meldingsclassificatie klopt met het incident, 3) hoe vaak er bij de classificatie Brand Gebouw sprake is geweest van brand en 4) hoe vaak er bij classificatie Alarm sprake is geweest van brand.

3.5.2 Methode

Data

Voor dit onderzoek is gebruikgemaakt van data afkomstig van de slimme vragenlijst (SVL) van de VRT (beschreven in paragraaf 2.2.2). Alle incidenten waarvoor de vragenlijst is ingevuld, zijn geïncludeerd. Incidenten uit de vragenlijsten kunnen van verschillen-de meldkamers en van buiten regiogrenzen komen; daar is niet extra op gefilterd. Wanneer meerdere eenheden een vragenlijst voor hetzelfde incident hadden ingevuld, is alleen de vragenlijst van de bevelvoerder van de eerst uitgerukte tankautospuit (TS 110) meegenomen in de analyse. Hierbij werd verondersteld dat deze vragenlijst de meest complete informatie over het incident bevatte. Als er bij een vraag meerdere antwoorden waren ingevuld, is alleen het laatste antwoord meegenomen.

Voor deelvraag 1 zijn de incidenten uitgesplitst naar de registratie in GMS (ter plaatse of niet ter plaatse) en op de status ‘tp geweest’ in de vragenlijst. Voor deelvraag 2, 3 en 4 zijn alleen de incidenten meegenomen die in GMS als ‘ter plaatse’ staan geregistreerd. Voor deelvraag 2 zijn deze incidenten vervolgens uitgesplitst naar meldingsclassificatie Brand of anders dan Brand en daadwerkelijk wel of geen brand volgens de vragenlijst. Voor deelvraag 3 is dezelfde selectie gebruikt als voor deelvraag 2, met als aanvullende voorwaarde dat de meldingsclassificatie in GMS Brand Gebouw of Brand Bijgebouw was. Voor deelvraag 4 is eveneens dezelfde selectie gebruikt als voor deelvraag 2, met als aanvullende voorwaarde dat de meldingsclassificatie in GMS Alarm was.

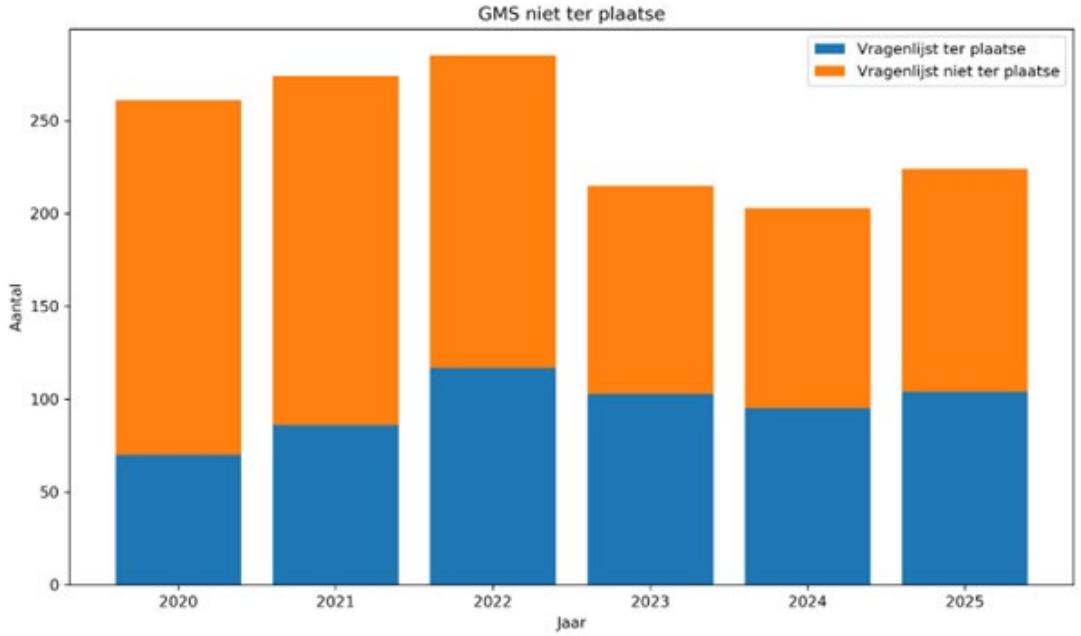
Analyse

De data zijn verwerkt tot visuele weergaven van frequentieverdelingen voor verschillende categorieën en groeperingen. Alle analyses zijn uitgevoerd in Python v3.13.9.

3.5.3 Resultaten

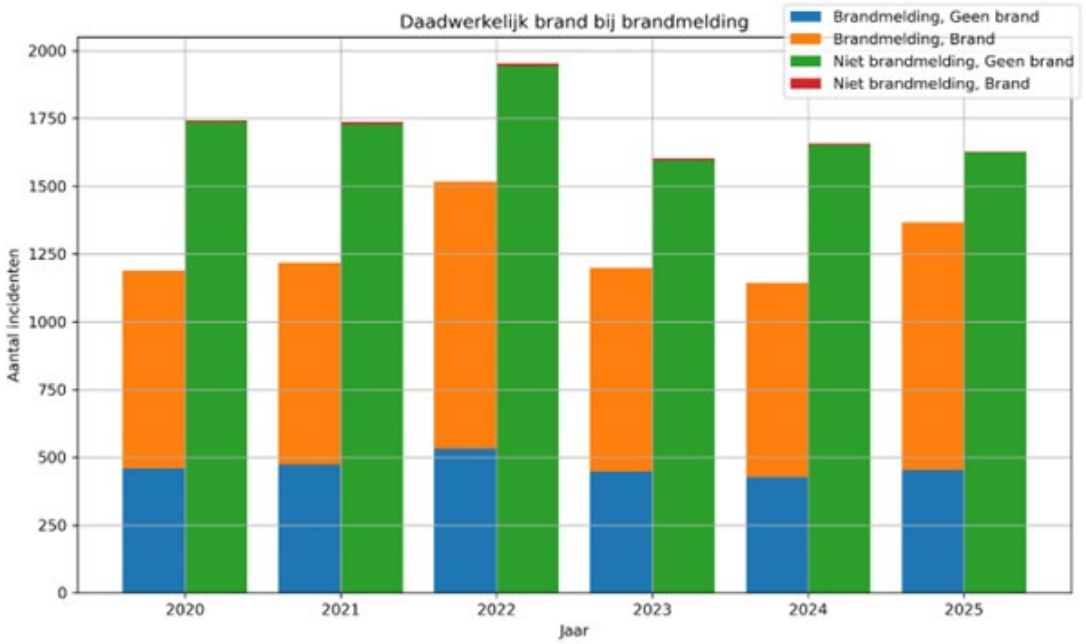
De initiële dataset bestond uit 20.231 incidenten. Tijdens de opschoning en filtering zijn 933 dubbele registraties verwijderd, waardoor 19.298 unieke incidenten overbleven voor analyse. Binnen deze opgeschoonde dataset waren 18.256 incidenten geregistreerd als ‘ter plaatse’ en 1.042 als ‘niet ter plaatse’. Voor de analyses van specifieke incidenttypen zijn aanvullen-de selecties gemaakt. De categorie Brand Gebouw omvatte 2.572 incidenten en de categorie Alarm 1.932 incidenten.

In Figuur 3.22 is het aantal incidenten met een ingevulde vragenlijst te zien, die op basis van GMS als afgebroken incident geclassificeerd zouden worden (geen status ter plaatse). Tussen de 25 % en 45 % van de incidenten is er volgens de vragenlijst echter wel een eenheid ter plaatse geweest. Deze incidenten ontbreken waarschijnlijk in de GMS-data, omdat er niet altijd een status gegeven wordt.



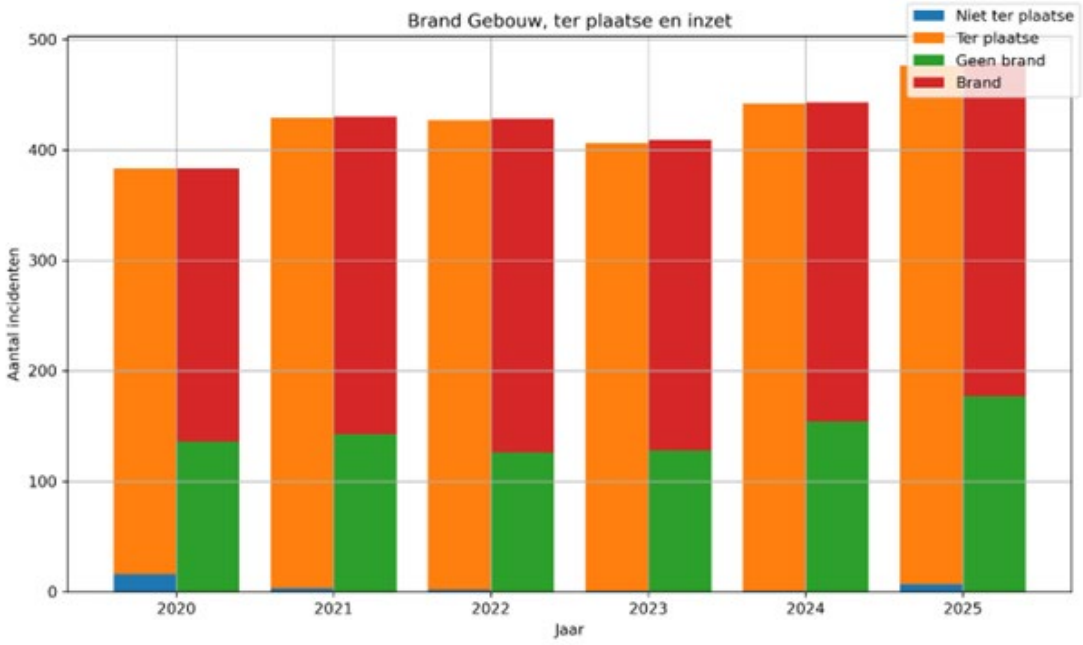
Figuur 3.22 Verdeling 'ter plaatse' en 'niet ter plaatse' in de vragenlijst voor incidenten met GMS-status 'niet ter plaatse'

Figuur 3.23 geeft het aantal incidenten weer waarbij volgens de vragenlijst sprake was van wel of geen brand, uitgezet tegen de gebruikte classificatie in GMS. Bij ongeveer 35 % van de brandmeldingen was er uiteindelijk geen sprake van brand. Bij minder dan 1 % van de niet-brandmeldingen was er toch sprake van brand. Brandmeldingen worden dus over het algemeen correct geclassificeerd, maar bij ter plaatste komst blijkt dat er soms geen sprake is van brand. Het kan wel zijn dat er dan een ander soort incident plaatsvindt.



Figuur 3.23 Aantal incidenten met en zonder brand volgens de vragenlijst, uitgesplitst naar GMS-classificatie

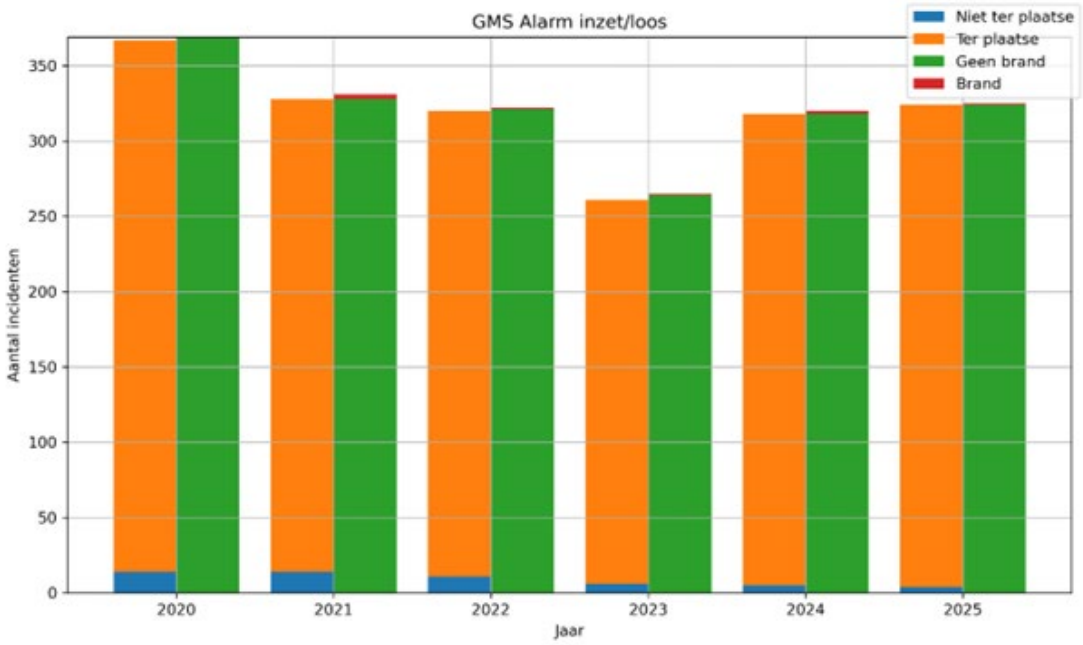
In Figuur 3.24 staat het aantal incidenten met classificatie ‘Brand Gebouw/Bijgebouw’ met volgens de vragenlijst wel of niet ter plaatse en wel of niet sprake van brand. Bij een melding van Brand Gebouw wordt er bijna altijd ter plaatse gegaan. In ongeveer 35 % van de gevallen wordt er bij plaatste komst geen brand aangetroffen.



Figuur 3.24. Verdeling van incidenten met classificatie ‘Brand Gebouw/Bijgebouw’ naar inzet ter plaatse en daadwerkelijke brand

Figuur 3.25 geeft het aantal incidenten met classificatie Alarm weer, gesplitst naar wel of niet ter plaatse en wel of niet sprake van brand. Bij de meldingsclassificatie Alarm is de brandweer in ongeveer 3 % van de gevallen niet ter plaatse geweest. Bij ongeveer 1 % van de

gevallen was er sprake van brand. Alarm is dus vaak loos. Bij daadwerkelijke brand kan de classificatie ook omgezet worden naar Brand Gebouw.



Figuur 3.25 Verdeling van incidenten met classificatie Alarm naar inzet ter plaatse en daadwerkelijke brand

3.5.4 Conclusie

De analyse laat zien dat incidentregistratie via vragenlijsten een duidelijke aanvulling vormt op de informatie uit GMS. Vragenlijsten bieden extra inzicht in de feitelijke situatie ter plaatse en maken het mogelijk meldingen en alarmeringen te verifiëren. Zo blijkt dat bij ongeveer 35 % van de brandmeldingen geen sprake is van een daadwerkelijke brand, terwijl bij alarmmeldingen slechts zeer zelden brand wordt vastgesteld. Dit kan verklaard worden door de meerwaarde van verificatiestappen bij automatische brandmeldingen zoals contrabellen of het omclassificeren van alarmmeldingen naar brand wanneer er daadwerkelijk sprake is van brand. Verder onderzoek naar de meldingsbron bij gemelde incidenten met classificatie brand kan verschillen veroorzaakt door omclassificering mogelijk aan het licht brengen.

De resultaten zijn gebaseerd op gegevens uit Twente, dus maar uit één VR. De generaliseerbaarheid is daarom afhankelijk van de beschikbaarheid, kwaliteit en wijze van implementatie van vragenlijsten in andere regio's. Ook regionale verschillen in risicoprofiel, meldkamerprocessen en operationele werkwijzen kunnen leiden tot afwijkende uitkomsten. Een beperking is dat alleen vragenlijsten van eenheden 110 (eerste tankautospuit ter plaatse) zijn meegenomen en dat de koppeling tussen vragenlijsten en GMS verder verbeterd kan worden.

Een limitatie van de analyse is dat de totalen van die berekend worden uit de vragenlijst soms wat hoger uitvallen dan de totalen die op basis van GMS data berekend worden. Deze kolommen zouden echter gelijk moeten zijn; het verschil is waarschijnlijk het gevolg van de gekozen analyseaanpak, waarbij een klein aantal (<5) vragenlijsten aan meerdere incidenten gekoppeld kunnen zijn. Hierin kan een verbeterslag worden gemaakt bij vervolgonderzoek. Voor deze exploratieve analyse werd dit echter niet rendabel geacht.

Desondanks worden de uitkomsten als betrouwbaar beschouwd, doordat een grote hoeveelheid data is gebruikt en slechts een beperkt aantal incidenten door de gehanteerde filters is uitgesloten. Bovendien sluiten de resultaten aan bij de verwachtingen vanuit de praktijk.

3.6 Procesanalyse

3.6.1 Inleiding

Voldoende inzicht in de doorlooptijd van een incident is van groot belang voor effectieve incidentbestrijding. De gegevens uit het GMS bieden de mogelijkheid om het verloop van incidenten te analyseren, vanaf de eerste melding tot en met de afronding van de inzet. Door de verschillende processtappen te onderzoeken, kan beter worden begrepen welke factoren bijdragen aan of invloed hebben op de duur van incidentafhandeling.

In dit deelonderzoek is de doorlooptijd van de incidentafhandeling bestudeerd en bekeken welke factoren van invloed zijn op de afhandeling. Daarbij zijn de tijdsintervallen tussen incidenttypes vergeleken en de samenhang tussen incidentgroottes en de duur van de afhandeling onderzocht. Ten slotte is onderzocht welke buurtkenmerken het meeste (of het minste) voorkomen in de buurten waar de incidenten plaatsvinden.

3.6.2 Methode

Data

Voor dit deelonderzoek is gebruikgemaakt van incidentdata en voertuigendata uit GMS, over de periode van 2021 tot en met 2025. De datasets werden gekoppeld op basis van incidentnummers (ID-nummers). Voor de analyses is gebruikgemaakt van gegevens van alle VR's die deze data beschikbaar hebben gesteld (VRAA, VRIJ, VNOG, VRGZ, VRT, VGGM en VRMWB).

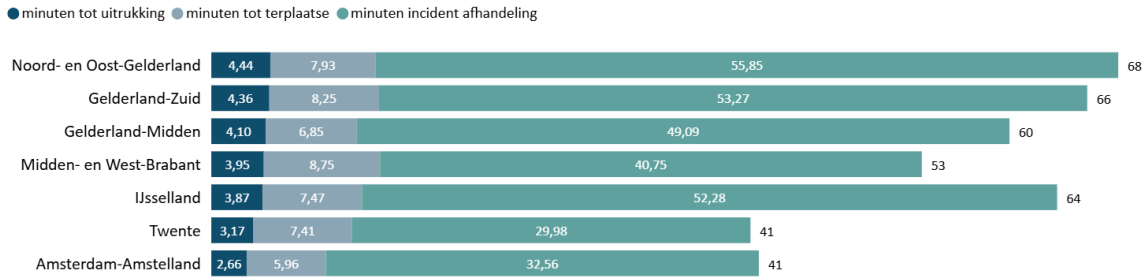
De *Kerncijfers Wijken en Buurten* die per jaar worden verzameld door het Centraal Bureau van Statistiek (CBS), zijn gekoppeld aan de incidentdata op basis van buurtcodes. Deze kerncijfers bevatten onder andere gegevens over de sociaal demografische kenmerken van een wijk of buurt.

Analyse

Het samenvoegen van de data en de uitvoering van de analyses zijn gedaan in Python (Gitlab, DATAPRO112 – 03 Procesanalyse). Om inzicht te krijgen in het tijdsverloop van incidenten per regio zijn er frequentietabellen en histogrammen gemaakt, die zijn verwerkt in een PowerBI rapport. De opkomsttijd is vervolgens berekend als het aantal seconden tussen de tijd van alarmering en de tijd ter plaatse van het eerste voertuig. Om de relatie tussen incidenten en de sociaal demografische kenmerken van een wijk of buurt te onderzoeken, is er een beschrijvende analyse toegepast. Voor elke numerieke CBS-variabele is een gewogen gemiddelde berekend, waarbij het aantal incidenten per buurt als weegfactor is gebruikt. Hierdoor wegen buurten met relatief veel incidenten zwaarder mee. De gemiddelden zijn vervolgens gerangschikt van hoog naar laag om te bepalen welke buurtkenmerken relatief sterk of juist zwak vertegenwoordigd zijn in het algemeen en per incidenttype.

3.6.3 Resultaten

Deze analyse begon met 245.058 unieke incidenten. Na exclusie van foutieve waarden (n=33) en outliers (n=23) zijn er 245.002 incidenten meegenomen in de analyse van buurtkenmerken. Voor de analyse die specifiek ging over het tijdsverloop van de inzet zijn 216.352 incidenten geïncludeerd, na exclusie van incidenten met ontbrekende status ('uitgerukt' of 'ter plaatse') en/of opkomsttijden (n = 28.650). In Figuur 3.26 is per regio weergegeven hoeveel minuten nodig waren voor de uitruk, de aanrijtijd naar de incident-locatie en de incidentafhandeling. De gemiddelde duur vanaf incidentmelding tot -afhande-ling varieerde van 41 minuten in VRT en VRAA tot 68 minuten in VNOG. De korte uitruktijd van 2,66 minuten in VRAA kan mogelijk worden verklaard door het relatief grote aandeel beroepsposten waar brandweermensen op de post aanwezig zijn op het moment dat de alarmering binnenkomt (circa 70 % van alle posten in VRAA), in tegenstelling tot de posten in andere regio's die voornamelijk op basis van vrijwilligers functioneren die na een alarmering naar de post moeten komen voordat zij kunnen uitrukken.



Figuur 3.26 Gemiddeld tijdsverloop van incident per regio

Om inzicht te krijgen in buurtkenmerken die mogelijk samenhangen met incidentmeldingen, is een top tien samengesteld van de meest en minst voorkomende buurtkenmerken (weergegeven in respectievelijk Tabel 3.7 en Tabel 3.8). Omdat elke buurt een bevolkingsdichtheid heeft en een totaalaantal inwoners en huishoudens, komen deze factoren bovenaan in de top tien te staan wanneer er gekeken wordt naar alle beschikbare kerncijfers. Daarom is er daarnaast een subanalyse uitgevoerd waarbij uitsluitend kenmerken zijn meegenomen die inhoudelijk relevant werden geacht voor de uitkomsten. Hierbij zijn kenmerken die betrekking hebben op aantallen, totalen en dichtheden buiten beschouwing gelaten (Tabel 3.7 en Tabel 3.8, 'Top 10 - Selectie'). De top tien geeft weer welke buurtkenmerken relatief sterk voorkomen in buurten met veel incidentmeldingen. Bovenaan staan kenmerken die het meest onderscheidend zijn, te herkennen aan een hoge score ('Gemiddelde waarden'). Zo zijn buurten met een groot aantal hoogopgeleiden, middelbaar opgeleiden, eenpersoonshuishoudens en inwoners van 25-45 jaar relatief sterk vertegenwoordigd. Ook kenmerken zoals een hogere WOZ-waarde, meer bedrijfsvesti-gingen en een groter aandeel 65-plussers komen vaker voor in buurten met veel meldingen. Hierbij gaat het om samenhang en niet per se om oorzakelijk verbanden.

Het hebben van meerdere personenauto's per huishouden, het hebben van een groter huishouden en het percentage personen dat in armoede leeft in een buurt lijken daarentegen factoren die het minste voorkomen in buurten met incidenten (Tabel 3.8).

Tabel 3.7 Top tien meestvoorkomende buurtkenmerken

	Top tien – Alle Kerncijfers				Top tien – Selectie		
	Kenmerk	Gemiddelde waarde	# buurten		Kenmerk	Gemiddelde waarde	# buurten
1	Bevolkingsdichtheid (inw/km²)	7398.11	2576	**1**	% Hoog opleidingsniveau	884.48	1681
2	Omgevingsadressendichtheid (adr/km²)	3071.74	2663	**2**	% Middelbaar opleidingsniveau	771.14	1970
3	Aantal inwoners	2365.62	2669	**3**	% 25-45 jaar	724.29	2669
4	Huishoudens totaal	1209.83	2669	**4**	% Eenpersoonshuishoudens	587.98	2669
5	Woningvoorraad	1159.81	2669	**5**	% 45-65 jaar	580.62	2669
6	Personenauto's totaal	920.51	2669	**6**	% Laag opleidingsniveau	578.84	1735
7	% Hoog opleidingsniveau	884.48	1681	**7**	Gem. WOZ-waarde (x 1.000 euro)	440.78	2404
8	% Middelbaar opleidingsniveau	771.14	1970	**8**	% 65 jaar of ouder	419.74	2669
9	% 25-45 jaar	724.29	2669	**9**	Bedrijfsvestigingen totaal	397.11	2669
10	% Eenpersoonshuishoudens	587.98	2669	**10**	% AOW-uitkering	391.29	2464

Tabel 3.8. Top 10 minst voorkomende buurtkenmerken

	Top 10 – Alle Kerncijfers				Top 10 – Selectie		
	Kenmerk	Gemiddelde waarde	# buurten		Kenmerk	Gemiddelde waarde	# buurten
1	Afstand kinderdagverblijf (km)	0.79	2573	**1**	Personenauto's per huishouden	0.87	2241
2	Personenauto's per huishouden	0.87	2241	**2**	Gem. huishoudensgrootte	2.02	2628
3	Afstand basisschool (km)	0.92	2573	**3**	% Personen in armoede	4.91	2329
4	Afstand grote supermarkt (km)	1.00	2573	**4**	% Aardgasvrije woningen	13.38	2041
5	Afstand huisartsenpraktijk (km)	1.10	2573	**5**	% Zelfstandigen	19.15	2056
6	Gem. huishoudensgrootte	2.02	2628	**6**	% Hoogste 20% inkomen	21.12	2288
7	Stedelijkheidsklasse (1=zeer sterk)	2.43	2663	**7**	Sterfte totaal	21.28	2669
8	% Personen in armoede	4.91	2329	**8**	Geboorten totaal	22.74	2669

	Top 10 – Alle Kerncijfers				Top 10 – Selectie		
	Kenmerk	Gemiddel-de waarde	# buurten		Kenmerk	Gemiddelde waarde	# buurten
9	% Aardgasvrije woningen	13.38	2041	**9**	% Woningen met zonnepanelen	25.27	2041
10	% Zelfstandigen	19.15	2056	**10**	% WW-uitkering	26.18	2464

Vervolgens is er per incidenttype een aparte top tien van buurtkenmerken gemaakt. Tussen meldingsclassificaties kan de volgorde van de top tien verschillen, maar blijft de inhoud nagenoeg hetzelfde.

3.6.4 Conclusie en discussie

De resultaten van dit onderzoek bieden meer inzicht in de duur van de procesafhandeling bij incidenten waarvoor de brandweer moet uitrukken. Hierbij zijn verschillen tussen VR's zichtbaar, die mogelijk samenhangen met de verhouding tussen beroeps- en vrijwillige brandweerposten. Daarnaast geeft dit onderzoek meer inzicht in buurtkenmerken die mogelijk verband houden met het voorkomen van incidenten. De resultaten laten zien dat vooral buurten met een relatief hoog opleidingsniveau en een groter aandeel inwoners in de leeftijdscategorie van 25 tot 45 jaar vaker vertegenwoordigd zijn onder buurten waar incidenten worden gerapporteerd. Deze bevolkingskenmerken kunnen mogelijk fungeren als proxy voor buurten met relatief veel studenten, starters of jonge gezinnen, waar het risico op brand door specifieke woon- en leefomstandigheden mogelijk hoger ligt. Omdat het hier slechts een beschrijvende analyse betreft, is deze hypothese niet verder onderzocht. Eerder onderzoek heeft al laten zien dat oudere woningen, vrijstaande en twee-onder-een-kapwoningen, huishoudens met kinderen en huishoudens met een lager inkomen een hoger risico hebben op woningbrand (Oosterveen et al., 2026). Hoewel er aanzienlijke overeenkomsten bestaan tussen incidenttypen, laten de resultaten ook zien dat de meest voorkomende buurtkenmerken enigszins kunnen verschillen, afhankelijk van het type melding.

Bij de interpretatie van de resultaten dient er rekening te worden gehouden met enkele beperkingen van dit onderzoek. Er zijn geen statistische analyses toegepast om daadwerkelijk te testen op mogelijke associaties of voorspellers. De resultaten geven daardoor uitsluitend een beschrijvend beeld van de situatie. Wel biedt het onderzoek perspectief voor vervolgonderzoek. Dit zou zich kunnen gaan richten op het verder structureren en groeperen van CBS-variabelen, evenals op een meer gerichte selectie van relevante buurtkenmerken.

3.7 Slachtoffers bij woningbranden

3.7.1 Inleiding

Het NIPV doet al jarenlang onderzoek naar de gevolgen van woningbranden. Zo worden gegevens verzameld en geanalyseerd over fatale woningbranden en wordt onderzoek gedaan naar reddingen bij woningbranden door de brandweer. Deze onderzoeken dragen bij aan het inzicht in de maatschappelijke impact van woningbranden en bieden aanknopingspunten voor preventie en risicobeheersing.

Over woningbranden waarbij weliswaar slachtoffers vallen, maar geen sprake is van een fatale afloop of een redding voor de brandweer, is veel minder bekend. Er bestaat momenteel geen structureel landelijk overzicht van het aantal woningbranden waarbij personen gewond raken. Verdere details over deze groep ontbreken ook. Hierdoor kunnen we geen compleet beeld krijgen van de gevolgen van woningbranden, hoewel dit totaalbeeld nodig is voor preventie, risicobeheersing en het verder verbeteren van incidentbestrijding.

Het ontwikkelen van een nieuwe landelijke registratie rondom slachtoffers bij woningbranden zou mogelijk meer inzicht kunnen bieden, maar brengt ook extra administratieve lasten met zich mee voor de VR's en hulpdiensten. Daarom is onderzocht of bestaande gegevensbronnen benut kunnen worden om woningbranden met slachtoffers in beeld te brengen.

Het doel van dit onderzoek is dan ook om te bepalen in hoeverre woningbranden met slachtoffers kunnen worden geïdentificeerd op basis van meldkamerdata, specifiek de informatie die is vastgelegd in kladblokregels. Hiervoor is onderzocht of machine-learning-modellen in staat zijn onderscheid te maken tussen woningbranden waarbij wel en geen slachtoffers betrokken waren, op basis van de tekst die tijdens het incident in het meldkamersysteem is geregistreerd.

3.7.2 Methode

Databronnen

Voor dit onderzoek zijn twee databronnen gebruikt: incidentgegevens uit slimme vragenlijsten van VRT uit de periode 2020 tot en met 2025 (beschreven in paragraaf 2.2.2) en kladblokgegevens uit het GMS van dezelfde regio en periode. De vragenlijsten vormden de basis voor het bepalen van het aantal woningbranden en beantwoorden van de vraag of bij een woningbrand slachtoffers betrokken waren. De kladblokgegevens uit GMS vormden de input voor de classificatiemodellen.

Selectie van woningbranden op basis van de vragenlijsten

Om tot een dataset van woningbranden te komen, zijn de data uit de vragenlijsten als volgt verwerkt. Eerst zijn vragenlijsten geselecteerd over de incidenten die branden betroffen in een gebouw met een woonfunctie. Hiermee ontstond een dataset van woningbranden. Daarna zijn uitsluitend vragenlijsten geselecteerd waarin was aangegeven dat de betreffende eenheid daadwerkelijk ter plaatse was geweest bij het incident. Het kwam voor dat een eenheid over één incident meerdere malen een vragenlijst had ingevuld. Daarom is van elk incident per eenheid uitsluitend de meest recent ingevulde vragenlijst geselecteerd.

Voor iedere woningbrand is vastgesteld of er volgens de ingevulde vragenlijst sprake was van slachtoffers. Bij twee incidenten waarvoor meerdere eenheden een vragenlijst hadden ingevuld, verschilden de antwoorden op de vraag of er slachtoffers waren. Deze incidenten zijn desondanks meegenomen in de analyse, aangezien het aannemelijk is dat niet alle eenheden over dezelfde informatie beschikten. Wanneer ten minste één eenheid aangaf dat er slachtoffers waren, is het incident geclassificeerd als een incident met slachtoffers. Er is geen onderscheid gemaakt naar de ernst van de verwondingen; de uitkomstvariabele bestond daarmee uitsluitend uit de categorieën slachtoffers aanwezig en geen slachtoffers aanwezig.

Koppeling GMS
De vragenlijsten van de geselecteerde woningbranden zijn gekoppeld aan de bijbehorende kladblokgegevens uit GMS. De koppeling is uitgevoerd op basis van de unieke incident-identificatie. Alle beschikbare kladblokregels zijn chronologisch samengevoegd tot één tekst.

Voorbewerking
Voordat de teksten konden worden gebruikt voor classificatie, zijn verschillende voorbewerkingsstappen uitgevoerd. Eerst zijn alle teksten omgezet naar kleine letters. Vervolgens zijn losse cijfers verwijderd, evenals veelvoorkomende meldkamercodes, bestaande uit twee letters gevolgd door vier cijfers of vier cijfers gevolgd door twee letters. Deze codes bevatten doorgaans geen inhoudelijke informatie over het incident. Verder zijn de teksten opgesplitst in afzonderlijke woorden (tokenisatie).

Tekstrepresentatie
Er zijn twee benaderingen gekozen, bij de eerste is gebruik gemaakt van TF-IDF (term frequency - inverse document frequency) en bij de tweede van tekst embeddings.
Bij TF-IDF wordt voor elk woord bepaald hoe kenmerkend het is voor een specifieke tekst ten opzichte van alle teksten. Voorafgaand aan het bepalen van de TF-IDF zijn Nederlandse stopwoorden verwijderd. Verder zijn modellen getraind op unigrammen (één woord), bigrammen (twee opeenvolgende woorden) en trigrammen (drie opeenvolgende woorden). Omdat niet vooraf duidelijk was welke manier van voorbewerken van de teksten het meest geschikt zou zijn, zijn twee varianten onderzocht. In de eerste variant zijn woorden teruggebracht tot een basisvorm (lemmatisatie). In de tweede variant zijn de oorspronkelijke woorden behouden gebleven.

De tweede benadering maakt gebruikt van tekst embeddings. Hierbij wordt een volledige tekst door een vooraf getraind taalmodel omgezet naar een numerieke vector die de betekenis van de tekst representeert. In tegenstelling tot TF-IDF wordt niet alleen gekeken naar het voorkomen van woorden, maar ook naar de semantische context waarin woorden voorkomen. Verschillende embeddingmodellen zijn onderzocht:
> mpnet-base-v2 (MPNet)
> e5-base
> e5-small
> bert-base-dutch-cased.

Modellen
Om te onderzoeken in hoeverre woningbranden met slachtoffers konden worden herkend op basis van kladblokteksten zijn verschillende classificatiemodellen toegepast:
> Logistic regression
> Random forest
> Gradient boosting
> Naive Bayes
> Complement Naive Bayes
> Support Vector Machine.

Bij de TF-IDF-representatie zijn alle bovenstaande classificatiemodellen toegepast. Bij de embeddingrepresentaties zijn uitsluitend Logistic Regression, Random Forest en Support Vector Machine gebruikt. Naive Bayes-methoden zijn niet geschikt voor continue embeddingvectoren en Gradient Boosting bleek vanwege de hoge dimensionaliteit en

rekentijd minder geschikt voor deze verkennende analyse. Er heeft geen optimalisatie van modelparameters (hyperparameter tuning) plaatsgevonden. Het doel van het onderzoek was namelijk niet het ontwikkelen van een optimaal voorspelmodel, maar het verkennen van de informatie die kladblokgegevens bevatten en in hoeverre verschillende classificatiemethoden woningbranden met en zonder slachtoffers kunnen classificeren.

TF-IDF (Term Frequency-Inverse Document Frequency) is een methode om te bepalen hoe belangrijk een woord is binnen een document, vergeleken met een verzameling documenten. Het bestaat uit twee onderdelen. De Term Frequency (TF) meet hoe vaak een woord voorkomt in een document. De Inverse Document Frequency (IDF) kijkt hoe zeldzaam dat woord is in alle documenten samen.

Het uitgangspunt daarbij is dat een woord belangrijk is wanneer het vaak voorkomt in één document, maar niet in veel andere documenten. Algemene woorden zoals lidwoorden komen in vrijwel elk document voor en krijgen daarom een lage score. Specifieke woorden zoals plaatsnamen, technische termen of unieke onderwerpen krijgen juist een hogere score.

Bij tekstanalyse worden termen vaak weergegeven als **unigrammen** of **bigrammen**. Een **unigram** bestaat uit één woord, bijvoorbeeld *brand*, *rook* of *Amsterdam*. Een **bigram** bestaat uit twee opeenvolgende woorden, bijvoorbeeld *grote brand*, *chemische fabriek* of *gevaarlijke stoffen*. Bigrammen geven vaak meer context dan losse woorden en kunnen daardoor betekenisvollere informatie opleveren.

In een verzameling brandweerrapporten krijgen veelvoorkomende woorden zoals *melding* of *incident* een lage TF-IDF-score, terwijl specifiekere termen zoals *lithium batterij*, *chemische fabriek* of *Amsterdam* juist een hogere score krijgen. TF-IDF wordt daarom veel gebruikt voor zoekmachines, kernwoordextractie, documentclassificatie en het identificeren van onderwerpen in grote hoeveelheden tekst.

Evaluatie

De modellen zijn beoordeeld met behulp van cross-validatie (5-fold stratified cross-validation) en aan de hand van precision en recall. Precision en recall zijn berekend aan de hand van de voorspellingen van een model versus de werkelijke categorie, zie ook Tabel 3.9. Precision geeft aan welk deel van de incidenten die door het model als woningbrand met slachtoffers worden geclassificeerd, daadwerkelijk slachtoffers had (TP / (TP + FP)). Recall geeft aan welk deel van alle woningbranden met slachtoffers door het model als zodanig wordt herkend (TP / (TP + FN)).

Tabel 3.9 Overzicht van voorspelling en daadwerkelijke situatie woningbrandenslachtoffers

	Woningbrand met slachtoffer(s)	**Woningbrand zonder slachtoffer(s)**
Voorspelling: slachtoffer(s)	True Positive (TP)	False Positive (FP)
Voorspelling: geen slachtoffer(s)	False Negative (FN)	True Negative (TN)

3.7.3 Resultaten

Een beschrijving van de data is weergegeven in Tabel 3.10. Op basis van de vragenlijsten uit de periode 2020 tot en met 2025 zijn in totaal 1.867 woningbranden geïdentificeerd. Bij 163 van deze woningbranden (8,7 %) was sprake van een of meer slachtoffers.

Tabel 3.10 Overzicht van de data

	2020	2021	2022	2023	2024	2025	Totaal
Aantal unieke vragenlijsten	3361	3329	3941	3191	3178	3408	20408
Aantal unieke incidenten	3017	3040	3588	2911	2891	3093	18540
Unieke incidenten brand	1132	1168	1497	1170	1283	1336	7586
Unieke incidenten woningbrand	253	338	323	315	322	316	1867
Woningbranden met slachtoffer(s)	22	29	29	26	27	30	163

Tabel 3.11 en Tabel 3.12 tonen de resultaten van respectievelijk de TF-IDF-modellen en de modellen op basis van tekstembeddings.

Tabel 3.11 Resultaten van de modellen op basis van TF-IDF

Model	Lemmatisatie	Ngram range	Precision	Recall	TP	FP	TN	FN
Gradient Boosting	Ja	(1, 1)	0,57	0,33	54	41	1663	109
		(1, 2)	0,52	0,33	53	49	1655	110
		(1, 3)	0,55	0,33	53	44	1660	110
	Nee	(1, 1)	0,48	0,29	47	51	1653	116
		(1, 2)	0,53	0,33	53	47	1657	110
		(1, 3)	0,56	0,32	52	41	1663	111
Logistische regressie	Ja	(1, 1)	0,42	0,76	124	174	1530	39
		(1, 2)	0,42	0,74	121	169	1535	42
		(1, 3)	0,42	0,74	121	165	1539	42
	Nee	(1, 1)	0,42	0,77	125	174	1530	38
		(1, 2)	0,42	0,75	122	167	1537	41

Model	Lemmatisatie	Ngram range	Precision	Recall	TP	FP	TN	FN
		(1, 3)	0,42	0,75	122	167	1537	41
Multinomial Naive Bayes	Ja	(1, 1)	0,33	0,01	1	2	1702	162
		(1, 2)	0,00	0,00	0	2	1702	163
		(1, 3)	0,00	0,00	0	2	1702	163
	Nee	(1, 1)	0,00	0,00	0	2	1702	163
		(1, 2)	0,33	0,01	1	2	1702	162
		(1, 3)	0,00	0,00	0	2	1702	163
Complement Naive Bayes	Ja	(1, 1)	0,31	0,67	109	238	1466	54
		(1, 2)	0,40	0,65	106	160	1544	57
		(1, 3)	0,39	0,62	101	159	1545	62
	Nee	(1, 1)	0,31	0,70	114	256	1448	49
		(1, 2)	0,38	0,68	110	181	1523	53
		(1, 3)	0,37	0,64	105	177	1527	58
Random Forest	Ja	(1, 1)	0,90	0,11	18	2	1702	145
		(1, 2)	0,59	0,12	20	14	1690	143
		(1, 3)	0,66	0,13	21	11	1693	142
	Nee	(1, 1)	0,75	0,13	21	7	1697	142
		(1, 2)	0,68	0,14	23	11	1693	140
		(1, 3)	0,64	0,15	25	14	1690	138
Support Vector Machine	Ja	(1, 1)	0,56	0,34	56	44	1660	107
		(1, 2)	0,61	0,38	62	40	1664	101
		(1, 3)	0,59	0,35	57	40	1664	106
	Nee	(1, 1)	0,54	0,33	53	46	1658	110
		(1, 2)	0,57	0,37	61	46	1658	102
		(1, 3)	0,58	0,36	59	42	1662	104

In Tabel 3.11 is te zien dat voor het model Gradient Boosting met lemmatisatie en alleen unigrams (n-gramrange 1-1) de precision 0,57 is en de recall 0,33. Dit betekent dat van alle incidenten die door het model als woningbrand met slachtoffer zijn geclassificeerd, 57 % daadwerkelijk een incident met slachtoffers was. Tegelijkertijd werd 33 % van alle werkelijke

woningbranden met slachtoffer correct geïdentificeerd. In totaal classificeerde het model 54 incidenten correct als woningbrand met slachtoffer (TP), terwijl 41 berichten ten onrechte als woningbrand met slachtoffer werden aangemerkt (FP).

Binnen de TF-IDF-benadering werden de beste resultaten behaald met logistische regressie. Het model zonder lemmatisatie en met uitsluitend unigrammen behaalde een recall van 0,77 en een precision van 0,42. Dit betekent dat 125 van de 163 woningbranden met slachtoffers correct werden herkend, terwijl 174 woningbranden zonder slachtoffers ten onrechte als woningbrand met slachtoffer werden geclassificeerd.

De resultaten laten zien dat de keuze voor lemmatisatie nauwelijks invloed had op de prestaties van de modellen. De verschillen tussen de varianten met en zonder lemmatisatie waren voor vrijwel alle classificatiemethoden beperkt. Ook het gebruik van grotere n-grams (bigrams en trigrams) leidde niet tot duidelijke verbeteringen. In sommige gevallen nam de precision licht toe, terwijl in andere gevallen juist een kleine afname zichtbaar was. Over het algemeen leverde het toevoegen van meer woordcombinaties geen substantiële winst op.

Naast logistische regressie presteerden ook Support Vector Machine en Gradient Boosting redelijk goed. Deze modellen behaalden doorgaans een hogere precision (ongeveer 0,55 tot 0,61) dan logistische regressie, maar hadden tegelijkertijd een aanzienlijk lagere recall (ongeveer 0,33 tot 0,38). Deze modellen waren daarmee selectiever in het signaleren van woningbranden met slachtoffers, maar misten ook een groter deel van de daadwerkelijke slachtofferincidenten. Random Forest behaalde de hoogste precision (tot 0,90), maar herkende slechts een klein deel van de woningbranden met slachtoffers (recall maximaal 0,15). Multinomial Naive Bayes presteerde duidelijk minder goed dan de overige modellen.

Tabel 3.12 Resultaten op basis van embeddingmodellen

Model	Embeddingmodel	Precision	Recall	TP	FP	TN	FN
Logistische regressie	mpnet	0,27	0,72	117	325	1379	46
	e5-base	0,39	0,87	141	325	1379	22
	e5-small	0,29	0,89	145	363	1341	18
	Bertbasedutchcased	0,17	0,32	52	257	1447	111
Random Forest	mpnet	0	0	0	0	1704	163
	e5-base	0	0	0	1	1703	163
	e5-small	0	0	0	0	1704	163
	Bertbasedutchcased	0	0	0	0	1704	163
Support Vector Machine	mpnet	0,48	0,14	22	24	1680	141
	e5-base	0,53	0,29	46	41	1663	117
	e5-small	0,54	0,26	42	36	1668	121
	Bertbasedutchcased	0,50	0,01	2	2	1702	161

Voor de embeddingbenadering (Tabel 3.12) werden vier verschillende embeddingmodellen onderzocht. De beste resultaten werden behaald met de E5-modellen in combinatie met logistische regressie. Het model gebaseerd op e5-small behaalde de hoogste recall (0,89), terwijl e5-base een recall van 0,87 combineerde met een hogere precision (0,39). Het e5-base-model herkende 141 van de 163 woningbranden met slachtoffers, terwijl 325 woningbranden zonder slachtoffers ten onrechte als slachtofferincident werden aangemerkt.

De resultaten laten zien dat de embeddingmodellen in staat waren een groter deel van de woningbranden met slachtoffers te herkennen dan de TF-IDF-modellen. De hoogste recall steeg van 0,77 voor TF-IDF naar 0,89 voor de embeddingmodellen. Daar stond tegenover dat de precision over het algemeen lager lag. De embeddingmodellen produceerden dus meer foutieve signaleringen van woningbranden met slachtoffers.

3.7.4 Conclusie

Een belangrijke vraag binnen dit onderzoek was of kladblokregistraties gebruikt kunnen worden om het aantal woningbranden met slachtoffers te monitoren. Voor een dergelijke toepassing is het wenselijk dat een model enerzijds zoveel mogelijk woningbranden met slachtoffers herkent en anderzijds zo min mogelijk woningbranden zonder slachtoffers foutief classificeert. Idealiter worden vrijwel alle woningbranden met slachtoffers gevonden, terwijl het aantal foutieve classificaties – woningbranden zonder slachtoffer die worden geclassificeerd als woningbrand met slachtoffer – beperkt blijft.

De resultaten laten zien dat het best presterende model een groot deel van de woningbranden met slachtoffers weet te identificeren. Van de woningbranden werd driekwart herkend. Tegelijkertijd werden echter een relatief groot aantal woningbranden zonder slachtoffers ten onrechte als woningbrand met slachtoffer geclassificeerd (n = 174). Het model overschat het aantal woningbranden met slachtoffers dus aanzienlijk. We concluderen daarom dat de onderzochte modellen niet gebruikt kunnen worden voor het schatten van het aantal woningbranden met slachtoffers.

3.8 Classificeren en clusteren kladbloktekst

3.8.1 Inleiding

In paragraaf 3.2 zijn de kenmerken van het kladblok geanalyseerd aan de hand van het aantal regels voor de diverse incidenttypen. Ook is daar duidelijk gemaakt dat de regels afkomstig uit externe systemen verschillen tussen de VR's. In dit hoofdstuk worden twee gerelateerde zaken verder uitgediept. Ten eerste wordt onderzocht in hoeverre de inhoud van de kladbloktekst kenmerkend is voor de VR en of de inhoud van de kladbloktekst gewijzigd is over tijd. Daartoe worden classificatiemodellen gebouwd om op basis van de kladbloktekst respectievelijk de VR en het jaar te classificeren. Als de kladbloktekst van de verschillende regio's niet onderscheidend is, zal de accuratesse van het classificatiemodel laag zijn. Omdat in paragraaf 3.2 duidelijk is geworden dat het gebruik van externe systemen verschilt tussen de regio's, is ook onderzocht hoe de accuratesse van de classificatiemodellen wijzigt over de tijd, zowel voor de kladbloktekst met regels afkomstig van externe systemen als voor de kladbloktekst zonder deze regels. De hypothese is dat de modellen in de meest recente jaren minder nauwkeuriger worden voor kladbloktekst zonder externe systeemregels ten opzichte van de jaren daarvoor, en ten opzichte van modellen gebaseerd op kladbloktekst met externe systeemregels. Ten tweede wordt onderzocht in hoeverre de

typering van de incidenten op basis van de kladbloktekst overeenkomt met de bestaande meldingsclassificaties en of er mogelijk nieuwe categorieën geïdentificeerd kunnen worden. De hypothese is dat het incident op basis van de kladbloktekst getypeerd kan worden.

3.8.2 Methode

Voor zowel het classificeren als het clusteren van de kladbloktekst moet de tekst worden omgezet naar een numerieke representatie. Daartoe worden na het uitfilteren van kladblokregels aangeduid als 'afkomstig van externe systemen' als eerste de volgende woorden en termen verwijderd: stopwoorden, elke term met getallen en termen bestaande uit één letter. Ook zijn alle vervoegde of verbogen woordvormen herleid tot hun basisvorm. Dit is een taalkundig proces dat lemmatisatie wordt genoemd. Voor deze procedure is gebruikgemaakt van het Spacy 'nl_core_news_sm' taalmodel (2026). Dit is een veelgebruikt taalmodel met een hoge accuratesse op lemmatisatie.

De termen zijn vervolgens omgezet naar een numerieke representatie met behulp van term-frequentie – inverse documentfrequentie (tf-idf; Wikipedia, 2026). Dit is een vrij klassieke methode om het belang van een term in het kladblok van een incident ten opzichte van de frequentie waarmee de term in het kladblok van alle incidenten voorkomt te bepalen. In de berekening van tf-idf worden niet alleen unigrammen meegenomen, maar ook bi- en trigrammen. Dat wil zeggen dat niet alleen enkele termen, maar ook combinaties van twee en drie termen worden geïncludeerd in de analyse. Daarnaast moet een term (combinatie) bij tenminste honderd incidenten voorkomen en niet vaker dan bij de helft van alle incidenten. Hiermee worden de heel zeldzame termcombinaties uitgesloten, evenals de zeer frequente combinaties.

Voor de classificatie van VR's worden Ridge-classificatiemodellen (α=1, Hilt, & Seegrist, 1977) getraind op 80 % van de data en getoetst op 20 % daarvan. Ridge-classificatiemodellen passen L2-regularisatie toe om overfitting te voorkomen. Daarmee zijn deze modellen geschikt voor situaties met veel variabelen, zoals hier het geval is.

Tekstclustering is een unsupervised machine learning methode die bestaat uit een aantal aanpasbare stappen. Hier is gekozen voor de klassieke methode.[12] Tekstclustering-methoden zijn toegepast voor de clustering van de kladbloktekst. Het kladblok bevat regio-afhankelijke termen en de inhoud lijkt over de jaren heen te veranderen (zie paragraaf 3.2). Ook de relatieve incidentfrequenties verschillen tussen regio's (zie paragraaf 3.1). Om een zuivere analyse op te zetten voor een categorisatie van incidenten op basis van kladbloktekst is een uniforme dataset van belang. Daarom is gekozen om voor de clustering enkel de incidenten afkomstig uit VNOG mee te nemen uit de jaren 2024 en 2025. Dit is een grote regio met veel en diverse incidenten. De recente jaren 2024 en 2025 zijn gekozen, omdat er over tijd wijzigingen zijn geweest in de registratie en op deze wijze een redelijk uniforme dataset is geselecteerd.

De resulterende matrix bevat een vrij groot aantal dimensies. Omdat clustering vaak beter werkt bij een lager aantal dimensies, wordt het aantal dimensies gereduceerd met behulp van truncated SVD. Dit is een lineaire dimensiereductie door middel van truncated singular value decomposition (SVD; Wikipedia, 2026). Deze methode werkt efficiënt op schaarse matrices en wordt vaak gebruikt in tekstanalyse. Het optimale aantal dimensies kan niet

[12] De moderne methode gebaseerd op Bertopics is ook geïmplementeerd, maar hier niet gerapporteerd in verband met tegenvallende resultaten.

objectief bepaald worden, maar moet worden afgeleid uit de knik (‘elleboog’) in de figuur waar de verklaarde variantie is afgezet tegen het aantal resulterende dimensies.

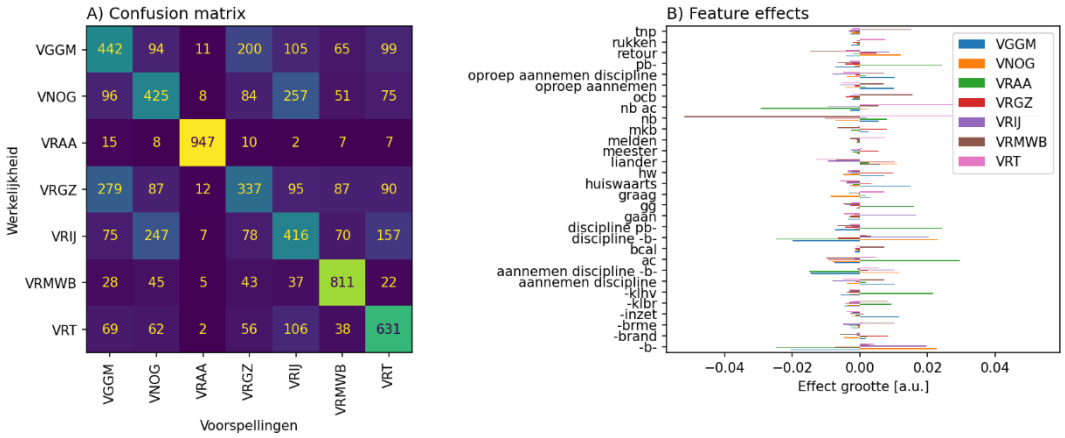
Het optimale aantal clusters dat moet worden toegepast in K-means wordt vervolgens bepaald door de Inertia, de Silhouette Score, de Clinski-Harbasc Index en de Davies-Bouldin Index uit te rekenen voor verschillende aantallen clusters. Het gevonden optimale aantal clusters wordt in K-means gebruikt voor de berekening. De resulterende clusters worden vergeleken met de bestaande meldingsclassificatie en gekenmerkt met de term(combinaties) met het hoogste gewicht in de clusterberekening.

In unsupervised machine learning is er geen objectieve maat voor de prestatie van het model. De resultaten worden daarom subjectief beoordeeld. Voor de figuren en analyses in dit hoofdstuk is gebruikgemaakt van Python versie 3.11. De code is beschikbaar in een Gitlab repository (Gitlab, DATAPRO112 - 01_incidentverificatie_en_clusteranalyse, z.d.); de ondersteunende packages zijn in deze repository opgenomen in het pyproject.toml bestand.

3.8.3 Resultaten

Eerst is een Ridge-classificatiemodel gebouwd om te onderzoeken of het mogelijk was om op basis van de data te voorspellen in welke VR de incidentmelding was gedaan. Hiervoor zijn 5000 willekeurige incidenten van elke regio gekozen. Deze aantallen vragen een beperkte rekentijd, terwijl ze toch nog wel een representatieve weergave geven. De numerieke representatie van de tekst bestaat uit 1604 kenmerken. Dit betekent, dat er gewerkt is met een matrix van 28000 x 1604 voor de trainingsset en 7000 x 1604 voor de testset. Positieve effecten tellen positief bij voor de categorie, negatieve effecten tellen negatief.

Figuur 3.27 zijn de resultaten weergegeven. De figuur laat zien dat de VR vrij goed kan worden bepaald op basis van de kladblokteks. De regio’s lijken regio specifieke termen te gebruiken.

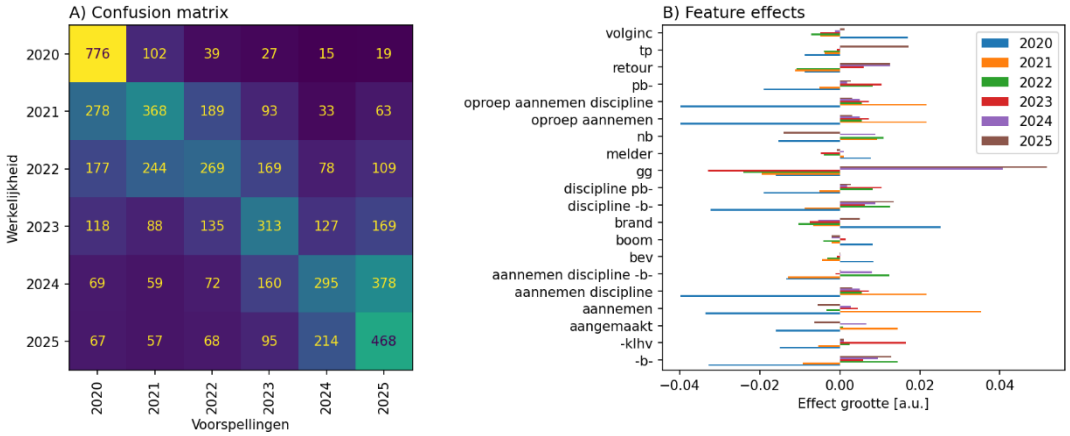


Positieve effecten tellen positief bij voor de categorie, negatieve effecten tellen negatief bij.

Figuur 3.27 De (A) confusion matrix van het Ridge-classificatiemodel voor de voorspelling van de VR met (B) bijbehorende feature effects voor de belangrijkste term(combinaties) in het model

Vervolgens is een Ridge-classificatiemodel gebouwd voor de voorspelling van het jaartal, waarbij 5000 willekeurige incidenten uit elk jaar gekozen zijn voor de dataset. De numerieke representatie van de tekst bestaat uit 1372 kenmerken, wat betekent dat er gewerkt is met een matrix van 24000 x 1372 voor de trainingsset en 6000 x 1372 voor de testset. In Positieve effecten tellen positief bij voor de categorie, negatieve effecten tellen negatief bij.

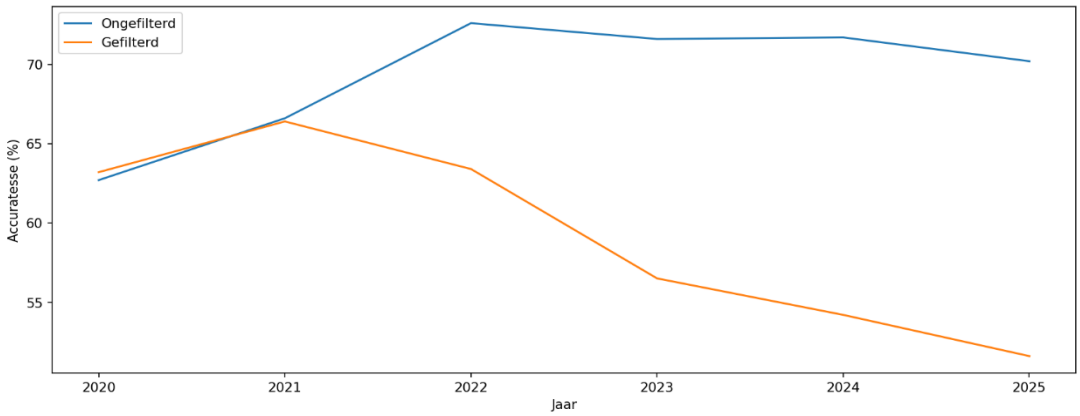
In Figuur 3.28 geeft een indicatie van de veranderingen die over de tijd hebben plaatsgevonden. Het laat zien dat het jaar goed bepaald kan worden op basis van de kladbloktekst, ook al is het jaar niet expliciet genoemd (alle termen met cijfers zijn verwijderd in de voorbewerking). Dit wil dus zeggen dat de kladbloktekst veranderd is over de jaren: kladbloktekst uit bijvoorbeeld 2022 ziet er anders uit dan kladbloktekst uit 2025.



Positieve effecten tellen positief bij voor de categorie, negatieve effecten tellen negatief bij.

Figuur 3.28. De (A) confusion matrix van het Ridge-classificatiemodel voor de voorspelling van het jaartal met (B) bijbehorende feature effects voor de belangrijkste term(combinaties) in het model

Er is ook voor elk jaar apart een Ridge-classificatiemodel gebouwd voor de voorspelling van de VR. Omdat niet elke regio 5000 gemelde incidenten per jaar heeft, is hier gekozen voor 2700 willekeurige incidenten per regio per jaar. Het aantal kenmerken varieert tussen de 722 en 1176. Figuur 3.29 laat de accuratesse van dit model zien voor zowel data mét de kladblokregels afkomstig van externe systemen (ongefilterd), als zonder (gefilterd). Terwijl de accuratesse voor de ongefilterde data de laatste jaren tamelijk hoog en constant is, zien we een afname voor de gefilterde data. Dit toont aan dat de kladbloktekst uniformer is geworden tussen de regio's (als de externe systemen buiten beschouwing worden gelaten), waardoor het steeds moeilijker wordt om de VR goed te voorspellen.



Figuur 3.29. De accuratesse van het Ridge-classificatiemodel voor de voorspelling van VR per jaar

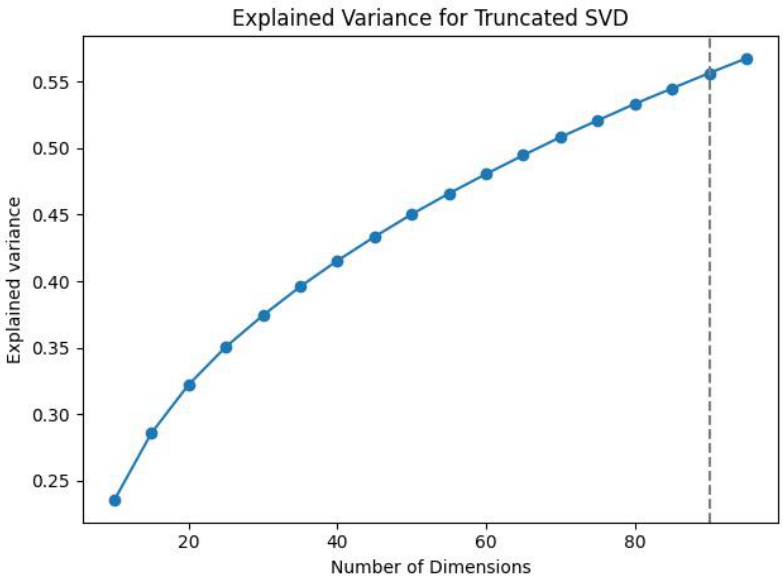
Bovenstaande methode leidt tot een reductie in het aantal kladblokregels en gemelde incidenten zoals weergegeven in Tabel 3.13. Vectorisatie met tf-idf leidt tot een dataset met

10109 incidenten en 691 kenmerken. De verklaarde variantie ten opzichte van het aantal dimensies staat in Figuur 3.30. Over het algemeen wordt een dimensie gekozen waarbij de verklaarde variantie een duidelijke knik (of 'elleboog') laat zien. Deze knik is echter niet duidelijk aanwezig in de figuur. Daarom is gekozen voor een dimensiereductie tot 90 dimensies (kenmerken), wat leidt tot een verklaarde variantie van circa 55 %. Dit is vrij hoog voor K-means clustering, maar lijkt noodzakelijk om voldoende variantie in het model op te nemen.

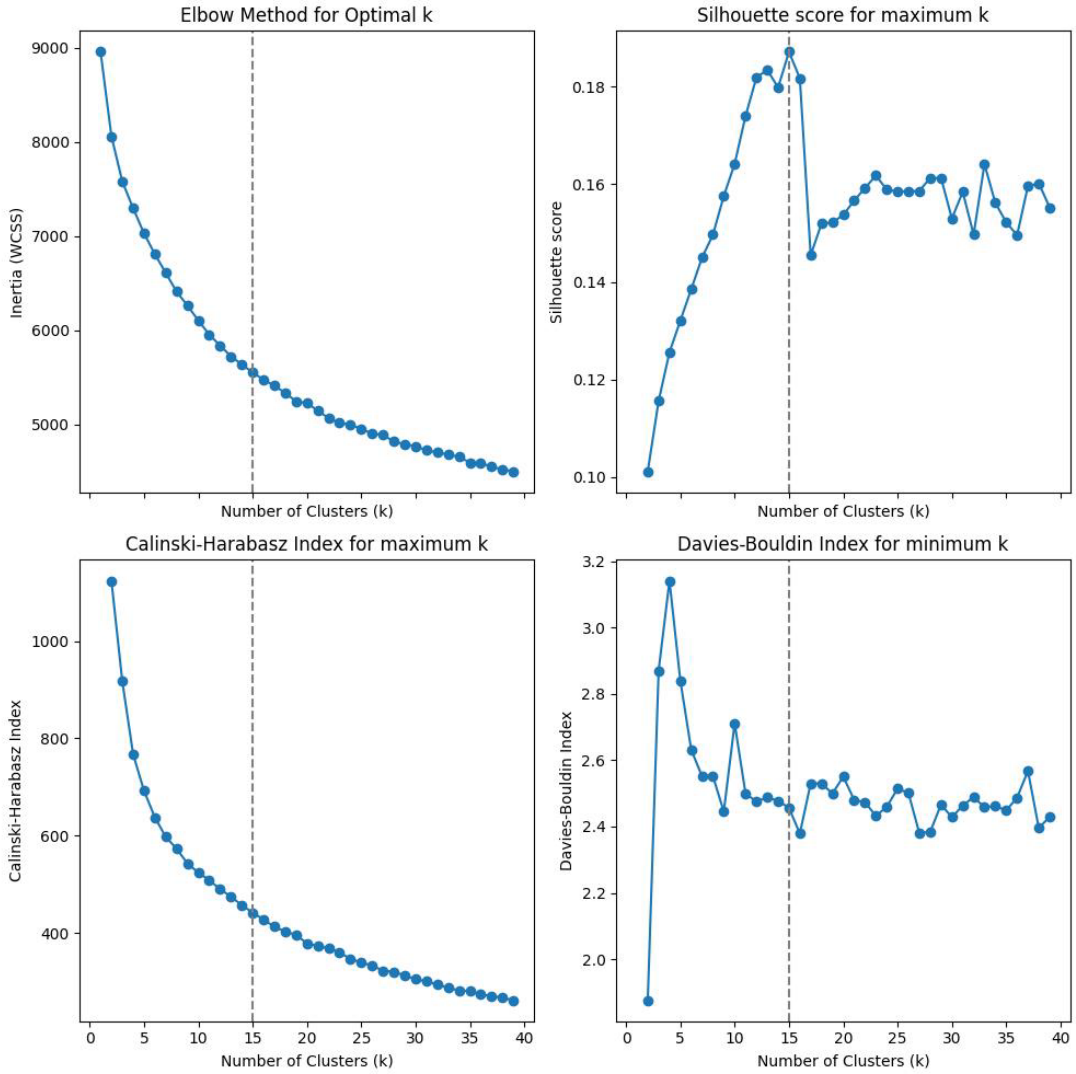
Tabel 3.13 Filterstappen in de tekstverwerking met resulterend aantal kladblokregels en gemelde incidenten

Filterstap	Aantal kladblokregels	Aantal gemelde incidenten
Initiële set	2062412	239702
Alleen jaren 2024 en 2025	784717	79946
Geen systeemregels	708421	79636
Alleen VNOG	91520	10109
Samenvoegen regels tot één tekst per incident, filteren van stopwoorden, woorden met cijfers, punctuatie, en woorden van 1 teken	n.v.t.	10109

De Inertia, de Silhouette Score, de Clinski-Harbasc Index en de Davies-Bouldin Index staan weergegeven in Figuur 3.31. De Inertia, en Clinski-Harbasc Index laten geen duidelijke knik zien voor het optimale aantal clusters. De Silhouette Score piekt echter bij ongeveer vijftien cluster en de Davies-Bouldin Index is daarbij ongeveer minimaal. Daarom worden vijftien clusters gekozen voor de K-means clustering.



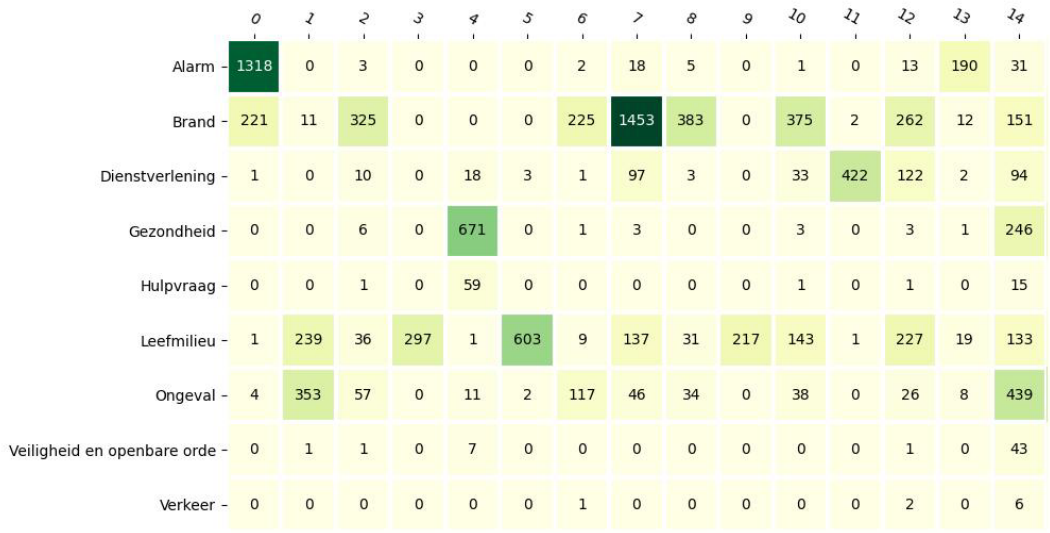
Figuur 3.30 De verklaarde variantie afgezet tegen het aantal dimensies voor Truncated SVD



Figuur 3.31 Van links naar rechts en boven naar beneden: de Inertia, de Silhouette Score, de Clinski-Harbasc Index en de Davies-Bouldin Index voor de bepaling van het optimale aantal clusters

Het resultaat van de clustering is weergegeven in Figuur 3.32. De gevonden clusters zijn genummerd van 0 – 14 en zijn weergegeven op de horizontale as. Op de verticale as staan de meldingsclassificaties. De getallen in de tabel geven het aantal incidenten weer. Voor elk cluster is aangegeven hoeveel incidenten in de bestaande meldingsclassificaties vallen. De meest representatieve term (combinaties) voor elk cluster staat in Tabel 3.14. In de beschrijving hieronder worden enkele opvallende clusters verder toegelicht.

De clustering liet zien dat cluster 0 met name uit automatische alarmmeldingen bestaat die dan ook vooral in de meldingsclassificatie ‘Alarm’ vallen en onder andere worden gekenmerkt door ‘minuut verstreken’ en ‘oms-timer’. De meeste alarmen zijn vals; enkele daarvan blijken echter wel echte brandmeldingen te zijn. Daarom valt cluster 0 ook gedeeltelijk onder de meldingsclassificatie ‘Brand’.



Figuur 3.32 Gevonden clusters

Cluster 1 bevat voornamelijk incidenten waarbij netbeheerder Liander een rol speelt. Dit betreft met name gasgerelateerde incidenten onder ‘Leefmilieu – stank/hinderlijke lucht’ en ongevallen met gevaarlijke stoffen. Stormgerelateerde incidenten (‘Leefmilieu – water- / weerproblemen’) lijken te zijn opgesplitst over tenminste drie clusters: cluster 3, 5 en 9. Deze opsplitsing lijkt te zijn veroorzaakt door de verschillende termen die gebruikt worden, namelijk ‘stormschade’, ‘ssbm’ (parserterm voor de karakteristiek ‘stormschade boom’) en ‘wpss’ (parserterm voor de meldingsclassificatie ‘stormschade’).

Voor sommige incidenten wordt voertuiginformatie opgevraagd. Deze incidenten worden teruggevonden in cluster 6 en vallen vooral onder de meldingsclassificaties ‘Brand’ en ‘Ongeval’. Voor andere incidenten wordt weerinformatie opgevraagd. Deze incidenten komen in cluster 8 terecht en betreffen met name incidenten met meldingsclassificatie ‘Brand’. De liftopsluitingen komen in cluster 11 terecht, hulpverlening aan patiënten in cluster 4 en koolstofmonoxidemeldingen in cluster 13.

Tot slot is er een verschil tussen het aannemen van oproepen en het aanmaken van oproepen, waarbij de eerste veelal het gevolg is van een telefoonoproep en het tweede door de centralist zelf wordt gedaan. Deze twee typen blijken voor een aantal gevallen te zijn uitgesplitst in de clusters 7 en 12, zoals voor de meldingsclassificatie ‘Brand’.

Tabel 3.14 Meest representatieve termen (combinaties) van de gevonden incidenten

Nr.	Meest representatieve term (combinaties)
0	verstreken, minuut verstreken, omstimer, minuut, oms-timer, timer, timer starten, oms-timer minuut, oms-timer minuut verstreken, starten
1	liander, liander tp, tp, oproep aangemaakt, aangemaakt discipline, oproep aangemaakt discipline, aangemaakt discipline -b-,
2	volginc, volginc oproep, discipline -b- volginc, -b- volginc, volginc oproep aannemen, oproep aannemen, aannemen discipline
3	-stormschade, -b- -stormschade, discipline -b- -stormschade, oproep aangemaakt discipline, oproep aangemaakt, aangemaakt discipline
4	patiënt, -ibtil, ambu, -ibafh, patiënt ambu, retour, brw, ambu gaan, nb, nb patiënt, overdragen ambu, overdragen, inpakken, gaan retour
5	-ssbm, discipline -b- -ssbm, -b- -ssbm, boom, oproep aangemaakt discipline, oproep aangemaakt, aangemaakt discipline
6	kg bj, bj, kg, auto, rijklr/max, rijklr/max kg, rijklr/max kg bj, zitplaats, bj deur, kg bj deur, bj deur zitplaats, deur zitplaats, pk, deur
7	brand, aannemen, aannemen discipline, oproep aannemen, oproep aannemen discipline, aannemen discipline -b-, rook, staan, nb
8	mm, bft, temp, grc, gr m/s, lv, neerslag, meetstation, grc lv, bft neerslag, gr m/s bft, m/s bft, gr, m/s bft neerslag, mm temp, mm mm
9	-wpss, -b- -wpss, discipline -b- -wpss, aangemaakt discipline -b-, oproep aangemaakt discipline, aangemaakt discipline
10	gebruiken, extern, coordinat gebruiken, extern coordinat, extern coordinat gebruiken, coordinat, gebruiken incidentadre, incidentadre
11	lift, persoon, persoon lift, -liftopsluiting, monteur, discipline -b- -liftopsluiting, -b- -liftopsluiting, vast, oproep aangemaakt discipline
12	oproep aangemaakt discipline, oproep aangemaakt, aangemaakt discipline, aangemaakt discipline -b-, aangemaakt, lucht, komen
13	melder, co, meten, co melder, -com, cv, ketel, meting, melder gaan, hangen, oproep aannemen, oproep aannemen discipline
14	brw, tp, nb, retour, ambu, persoon, voertuig, politie, graag, komen, @pol, gaan retour, rijden, mee, mkb, ovd, nodig, prio, so, alarmeren

3.8.4 Conclusie

De regio en ook het jaar kan vrij goed achterhaald worden uit de kladbloktekst. Dit laat zien dan de kladbloktekst inhoudelijk verschillend is tussen regio's en over de tijd. Ook na filtering van de externe systeemregels kan de regio nog geïdentificeerd worden aan de hand van de kladbloktekst, zoals blijkt uit de voorspelmodelresultaten. De bijbehorende kenmerken laten echter nog wel termen zien die uit automatische systemen afkomstig lijken te zijn, zoals 'aannemen discipline' en 'volginc'. De regels waarin deze termen voorkomen, zijn niet aangeduid als afkomstig uit automatische systemen maar lijken dat wel te zijn.[13]

Met de externe systeemregels kan de VR jaar op jaar behoorlijk goed uit de kladbloktekst worden afgeleid. Zonder deze systeemregels gaat dat geleidelijk aan steeds slechter, wat erop lijkt te duiden dat de kladblokteksten van de verschillende regio's meer op elkaar gaan lijken. Mogelijk zien we hier het effect van de oprichting van Meldkamer Oost-Nederland op 21 maart 2023, waardoor het aantal bediende VR's van twee naar vijf is gegroeid. Na de oprichting is gewerkt aan verdere harmonisatie.

De clustering op data van de VNOG en de jaren 2024 en 2025 leidt over het geheel genomen tot verklaarbare en betekenisvolle clusters. Incidenten zoals alarmen, CO-meldingen en liftopsluitingen komen duidelijk naar voren in de clustering. De resultaten zijn echter ook afhankelijk van de gebruikte termen. Voor stormschade kan zowel de parserterm '-stormschade' als het equivalent '-wpss' gebruikt worden. De parserterm '-ssbm' staat voor de karakteristiek stormschade boom en geeft daarmee wat extra duiding aan het incident. De mogelijk willekeurige keuze van de centralist om de ene of de andere term te gebruiken, leidt tot verschillende clusters, terwijl deze incidenten eigenlijk in hetzelfde cluster terecht hadden moeten komen. Dit wordt veroorzaakt doordat het gebruikte taalmodel geen semantische betekenis toekent aan de termen: 'stormschade' verschilt in het model evenveel van 'wpss' als van 'liftopsluiting'.

Modernere taalmodellen kennen wel semantische betekenis toe. Deze modellen kunnen onderscheid maken tussen 'bank' als meubel en als financieel instituut op basis van de context. Hiervoor zijn goed gestructureerde zinnen noodzakelijk en algemeen bekende en gebruikte woorden. Kladbloktekst bestaat echter uit korte notities, soms slechts enkele woorden per regel, en domeinspecifieke parsertermen die geen onderdeel uitmaken van bestaande taalmodellen.

Het aantal regels, termen en woorden in de kladbloktekst bij een incident is tamelijk laag, met een mediaan onder de tien regels (zie paragraaf 3.2). Daarmee is de hoeveelheid te extraheren informatie per incident inherent ook beperkt. Voor toekomstig onderzoek zou het interessant zijn om de semantische betekenis van parsertermen en andere domeinspecifieke termen expliciet in het model op te nemen.

De clustering is enkel voor de kladbloktekst van de VNOG uitgevoerd; daardoor is een generalisatie naar de overige regio's lastig te maken. Voordat de analyse wordt herhaald voor meerdere regio's, moet worden onderzocht hoe het model de verschillen in kladblok-tekst tussen de regio's op een juiste manier kan incorporeren zonder dat de clustering hierdoor verstoord wordt. Na uitbreiding van de clustering naar meerdere regio's zou kunnen worden nagedacht over een mogelijke implementatie van de gevonden clusters in een nieuwe meldingsclassificatie-indeling. Hiervoor zou goed moeten worden onderzocht of de

[13] Persoonlijke communicatie met Joop Wessels.

clustering past bij een goede manier van werken en incidentbestrijding in de praktijk. Ook moet er rekening mee gehouden worden dat grote wijzigingen in de manier van werken van alle centralisten vaak lastig te implementeren zijn. Daarnaast is de huidige indeling in meldingsclassificaties leidend in de presentatie van cijfers, zoals op het dashboard *Kerncijfers Incidenten* (NIPV, z.d.). Een nieuwe indeling zou een breuk betekenen met eerder gepubliceerde cijfers. De huidige clusterresultaten kunnen daarom het beste als inspiratie beschouwd worden voor de ontwikkeling van een beter model voor de classificatie en karakterisering van incidenten.

3.9 Trendanalyse in kladblokregels

3.9.1 Inleiding

Bij meldkamers zijn grote hoeveelheden data beschikbaar in de vorm van vrije invoer door centralisten. Deze gegevens worden niet volgens een vaste structuur vastgelegd, waardoor de inhoud sterk kan variëren per melding en per centralist. Dit maakt het lastig om op een eenduidige en systematische manier informatie uit deze data te halen. Hierdoor blijft waardevolle informatie vaak verborgen in de grote hoeveelheid tekst. Door deze data te analyseren met behulp van een trendanalyse kan mogelijk toch inzicht worden verkregen in patronen en ontwikkelingen die relevant zijn voor beleidsvorming, planning en operationele inzet. De onderzoeksvraag die centraal staat in deze paragraaf luidt: *In hoeverre kunnen met behulp van trendanalyse bruikbare patronen en ontwikkelingen worden geïdentificeerd in ongestructureerde kladblokregels uit meldkamers van meerdere VR's?*

Om deze vraag te beantwoorden, zijn meerdere deelanalyses uitgevoerd van de kladblok-data uit verschillende VR's. Hierbij is gekeken naar onder andere frequenties, patronen en mogelijke trends.

3.9.2 Methode

Data

Voor de analyse is gebruikgemaakt van de data 7 VR's, waarvan de data na fusies komt uit drie meldkamers. In Tabel 3.15 staat een overzicht per jaar van de kladblokregels die de afzonderlijke meldkamers hebben aangeleverd.[14]

[14] De veiligheidsregio's werken met eigen of gezamenlijke meldkamers, waarin de kladblokregels worden vastgelegd. In dit onderzoek worden de meldkamers AD (Veiligheidsregio Amsterdam-Amstelland), GLM (Veiligheidsregio Gelderland-Midden), MON (Veiligheidsregio's IJsselland en Noord- en Oost-Gelderland), TWT (Veiligheidsregio Twente) en ZB (Veiligheidsregio Midden- en West-Brabant en Zeeland) onderscheiden. Meldkamer ZB neemt deel aan het project; Veiligheidsregio Zeeland maakt echter geen onderdeel uit van het project. In 2023 zijn GLM en TWT samengegaan met MON in meldkamer Oost-Nederland (ON). Hierdoor zijn vanaf begin 2023 voor deze meldkamers geen kladblokregels meer beschikbaar, wat in de gegevens resulteert in waarden van 0.

Tabel 3.15 Totaal aantal aangeleverde kladblokregels per jaar per meldkamer

Jaar	AD	GLM	MON	ON	TWT	ZB
2020	11708	8859	7500	0	4058	4687
2021	11874	8519	6956	0	3794	7327
2022	13083	9969	8720	0	4279	8852
2023	11650	1808	1476	15456	845	8034
2024	12002	0	0	19607	0	7005
2025	12064	0	0	21353	0	7746

Deze kladblokregels zijn beschikbaar gesteld in hun meest ruwe vorm. Ze zijn per invoer vastgelegd. Tijdens de analyse zijn alle kladblokregels samengevoegd, zodat per incident één doorlopend verhaal kon worden gevormd.

Filtering
Er heeft een aantal filteringstappen plaatsgevonden. In Tabel 3.16 zijn deze stappen uitgewerkt. Eerst is tekstfiltering toegepast om verschillende woorden te verwijderen, zoals de parsertermen. Dergelijke opschoningen kunnen lege regels veroorzaken; deze zijn er in de volgende stap uitgehaald (Tabel 3.17).

Tabel 3.16 Tekstuele opschoning

Stap	Beschrijving
Initiële kladblokregels	
Lowercasing	Tekst omzetten naar lowercase
Parsertermen verwijderen	Woorden die beginnen met "_"
Cijferfilter	Getallen groter dan 3 cijfers (veelal voertuignummers)
Punctuatie verwijderen	Alle symbolen en leestekens verwijderen (behalve letters, cijfers en spaties)
Spaties opschonen	Meerdere spaties vervangen door één spatie en trimmen
Stopwoordenfilter	Veelvoorkomende functiewoorden verwijderen
Domeinwoordenfilter	Specifieke meldkamertermen verwijderen
Lengtecontrole	Minder dan 3 woorden → verwijderen (lege output)

Tabel 3.17. Kladblokopschoning

Stap	Aantal
Initiële kladblokregels	2062412
Systeemregels verwijderen	1707287
Lege en NULL regels (veroorzaakt door tekstopschoning, vorige tabel) verwijderen	1704285
Kladblokregels samenvoegen per incident	239233

Analyse

Dit onderzoek betreft een beschrijvende analyse, waarbij de nadruk ligt op het verkennen van de beschikbare data zonder het doen van voorspellingen of het verklaren van oorzaken. De dataset is opgebouwd uit meerdere Parquet-bestanden die zijn samengevoegd tot één geheel. Vervolgens zijn de kladblokregels per incident geordend en samengevoegd tot één doorlopende tekst, zodat per incident één document beschikbaar is voor analyse. De analyse is uitgevoerd in Python v3.11.15. De code is beschikbaar in de Gitlab repository (Gitlab, DATAPRO112 – 02 trends incidenten, z.d.); de ondersteunende packages zijn in deze repository opgenomen in het pyproject.toml bestand.

Voor de tekstanalyse is gebruikgemaakt van een preprocessingstap waarin de data zijn opgeschoond, zodat de tekst beter geschikt is voor modellering. Voor het identificeren van onderwerpen is het BERTopic-model toegepast. BERTopic is een topic modelling-techniek die teksten niet alleen op basis van woordfrequentie analyseert, maar vooral op basis van semantische betekenis. Hiervoor zijn eerst embeddings gegenereerd met een SentenceTransformer-model (paraphrase-multilingual-MiniLM-L12-v2). Deze embeddings zetten tekst om naar numerieke vectoren waarin de betekenis van zinnen wordt vastgelegd, waardoor vergelijkbare teksten dichter bij elkaar in de vectorruimte komen te liggen. Vervolgens wordt UMAP[15] gebruikt om deze hoge-dimensionale vectoren te reduceren naar een lagere dimensie. Dit maakt het mogelijk om de structuur van de data te behouden, maar de complexiteit te verlagen, zodat clustering efficiënter kan plaatsvinden. Daarna is HDBSCAN[16] toegepast. Dit algoritme groepeert teksten automatisch op basis van dichtheid in de data, waardoor clusters (topics) ontstaan zonder dat vooraf het aantal clusters hoeft te worden bepaald. Teksten die niet goed in een cluster passen, zijn als ruis behandeld. Om de topics beter interpreteerbaar te maken, is CountVectorizer gebruikt om belangrijke woorden per cluster te bepalen op basis van frequentie (unigrams en bigrams). Daarnaast is Maximal Marginal Relevance (MMR) toegepast om ervoor te zorgen dat de belangrijkste termen binnen een topic niet te veel op elkaar lijken, waardoor de interpretatie diverser en duidelijker wordt. Het resultaat is een set topics die semantische groepen van kladblokregels weergeven en die de basis vormen voor de verdere trendanalyse.

Het duiden en interpreteren van de gevonden topics is in dit onderzoek een uitdagend onderdeel gebleken. Door de grote hoeveelheid gegenereerde topics en het gebruik van een unsupervised leermethode is niet altijd direct duidelijk wat de exacte inhoud of betekenis van een topic is. De clustering is volledig datagedreven, waardoor interpretatie achteraf

[15] Uniform Manifold Approximation and Projection.
[16] Hierarchical Density-Based Spatial Clustering of Applications with Noise.

noodzakelijk is om betekenis te geven aan de resultaten. Om dit te ondersteunen zijn verschillende visualisaties en analyses toegepast, waaronder grafieken van topic-ontwikkelingen over tijd. Daarnaast is gekeken naar de grootste stijgers en statistisch significante stijgingen binnen topics om te bepalen welke onderwerpen in de praktijk het meest relevant of interessant zijn voor verdere analyse.

3.9.3 Resultaten

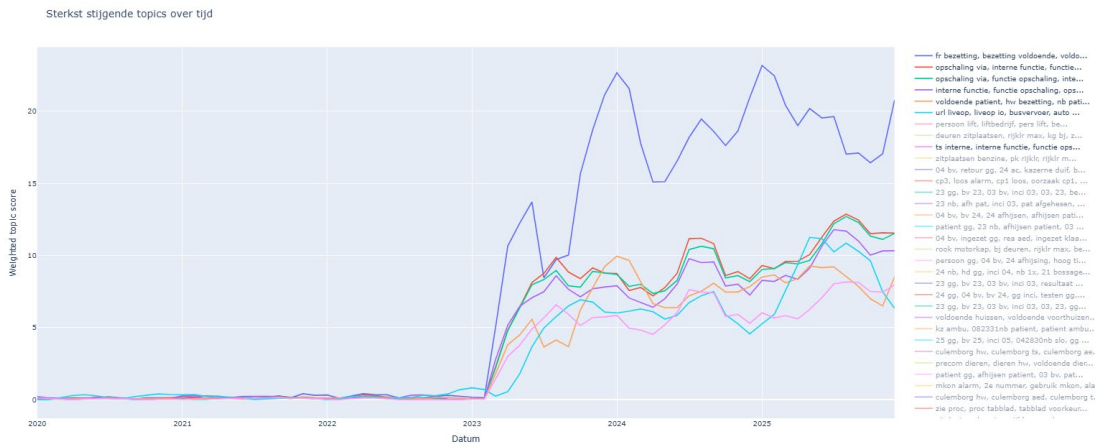
Geëxtraheerde topics

Het uitvoeren van de geconfigureerde BERTopic-analyse nam ongeveer 34 uur in beslag. Het grootste deel van deze rekentijd is besteed aan het clusteren van de embeddings tot semantisch vergelijkbare groepen. Na afronding van de analyse zijn in totaal 1.926 topics geïdentificeerd. Het duiden van de topics is lastig; de topics worden beschreven door middel van de meest voorkomende en belangrijkste woorden. Sommige topics lijken specifiek en makkelijk te duiden zoals een topic over gaslekkages en een topic over liftopsluitingen. Andere daarentegen zijn lastiger te duiden door een meer gevarieerd palet van termen. Tabel 3.18 geeft een greep uit de eerste topics.

Tabel 3.18 Eerste topics van BERTopic analyse

Topics	Belangrijkste woorden
Topic 1	persoon lift_liftbedrijf_pers lift_bevrijd lift
Topic 2	waterleiding_gesprongen_hoofdkraan_kelder
Topic 3	gasleiding geraakt_meter gevel_huisaansluiting_graafwerkzaamheden
Topic 4	ongeval_persoon bekneld_so auto_auto sloot
Topic 5	scooter geblust_bromfiets pk_elektrische scooter_scooter scooter
Topic 6	auto volledig_brand auto_volledig brand_auto staat
Topic 7	meter gevel_graafwerkzaamheden_mtr gevel_leiding geraakt
Topic 8	dakpannen_platen_zink_waaien dak
Topic 9	pijp_kanaal_rook woning_vlammen schoorsteen
Topic 10	politie ingezet_politie graag_politie geeft_reanimatie aed
Topic 11	brand keuken_kookplaat_rook keuken_rook oven
Topic 12	koeien_kalveren put_nb koe_koe sloot
Topic 13	fietspad boom_boven fietspad_boom verwijderd_fietspad weer

Topics die over de tijd duidelijk veranderen in frequentie zijn vooral interessant: topics die over de tijd vaker voorkomen en daarmee mogelijk opkomende trends vormen, maar ook topics die juist minder vaak voorkomen of verdwijnen. Figuur 3.33 toont de sterkste stijgers.

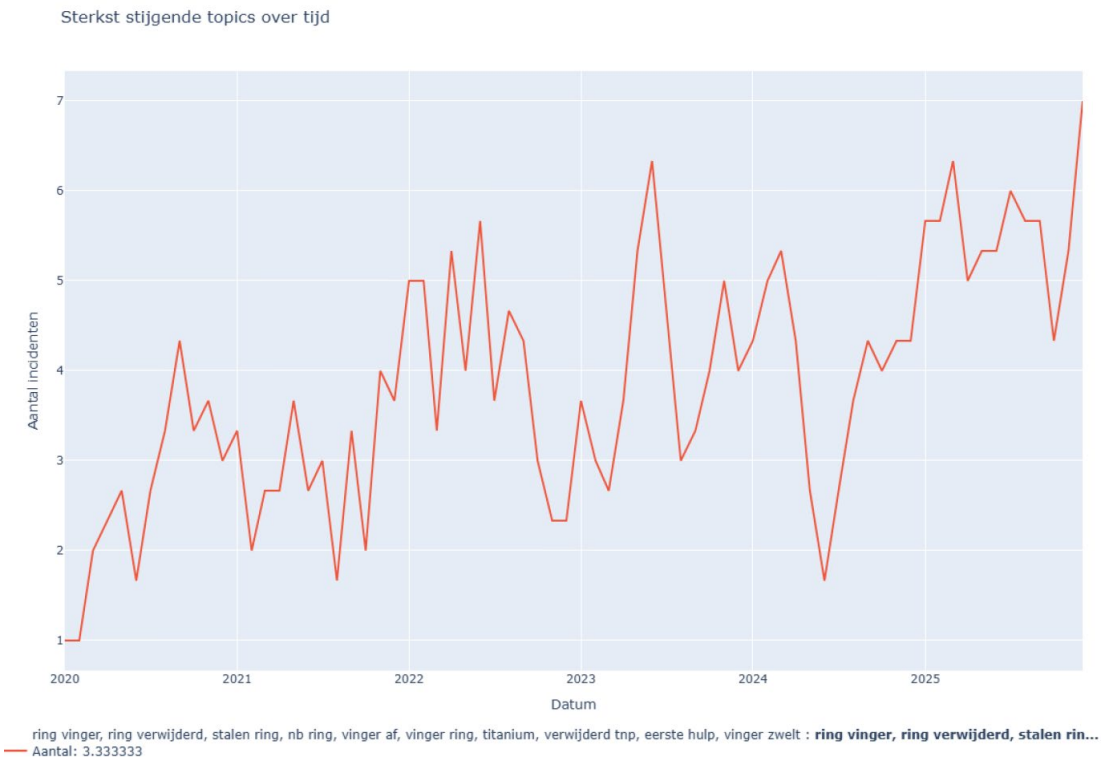


Figuur 3.33 Sterkst stijgende topics over de tijd

Een aantal topics volgt het hierboven beschreven patroon. Deze topics laten vanaf 2023 een plotselinge sterke toename zien. Hoewel een aantal systeemkladblokregels met een vergelijkbaar patroon vooraf uit de dataset is verwijderd, vertonen nog steeds verschillende topics deze ontwikkeling. Dit betekent echter niet dat deze topics automatisch aan systeemkladblokregels kunnen worden toegeschreven. Een mogelijke verklaring voor deze stijging is de ingebruikname van de meldkamer Oost-Nederland in 2023, waardoor de samenstelling en omvang van de beschikbare data zijn veranderd. Naar verwachting verklaart dit echter niet alle topics met dergelijk patroon.

Specifieke topics

Uit de lijst met gevonden topics komt een gevarieerd beeld naar voren. Sommige topics vertegenwoordigen een duidelijk afgebakend thema, terwijl andere minder eenduidig te interpreteren zijn. Desondanks zijn er verschillende topics die betrekking hebben op zeer specifieke typen incidenten of werkzaamheden, zoals: het plaatsen van zichtschermen, de inzet van het Team Collegiale Ondersteuning (TCO), gaslekkages, incidenten met koolmonoxidemeldingen en incidenten waarbij een paard in een sloot terecht is gekomen. Een aantal van deze onderwerpen wordt niet expliciet vastgelegd in de gestructureerde velden van GMS, maar kan wel worden geïdentificeerd op basis van de vrije tekst in de kladblokregels. Dit laat zien dat de ongestructureerde data aanvullende informatie bevatten die met traditionele registraties minder eenvoudig zichtbaar is. Daarnaast is een opvallend topic gevonden dat betrekking heeft op het verwijderen van een ring van een vinger (Figuur 3.34). Hoewel dit een specifiek type inzet betreft, komt het regelmatig voor binnen de brandweerpraktijk en blijkt het voldoende onderscheidend om door het model als afzonderlijk topic te worden herkend. Dit incident is niet bij één specifieke meldkamer gevonden, maar voornamelijk bij de meldkamers, ZB, AD en ON.



Figuur 3.34 Verwijderen van ring van vinger

De bovenstaande bevindingen laten zien welke aanvullende inzichten uit de ongestructureerde data kunnen worden verkregen. Tegelijkertijd roept dit beleidsmatige vragen op over de aard van de werkzaamheden die de brandweer uitvoert en in hoeverre dergelijke inzetten tot de kerntaken van de brandweer worden gerekend.

Droge periodes

Opvallend is dat een aantal topics betrekking heeft op bermbranden, natuurbranden en droogte. Deze topics omvatten elk een verschillend aantal incidenten. Wanneer de ontwikkeling van deze topics in de tijd over elkaar heen wordt geplot (Figuur 3.35), vertonen de lijnen een vergelijkbaar patroon. Daarbij zijn enkele duidelijke piekmomenten zichtbaar, die lijken samen te vallen met de droge perioden die zich de afgelopen jaren hebben voorgedaan. Een controle van de gegevens van het KNMI bevestigt dit beeld:

> September 2020: Warm, zeer zonnig en vrij droog[17]
> Augustus 2022: Zeer warm, zeer droog en extreem zonnig[18]
> Juni 2023: Recordwarm en zeer droog[19]
> Mei 2025: Vrij zacht, droog en zeer zonnig.[20]

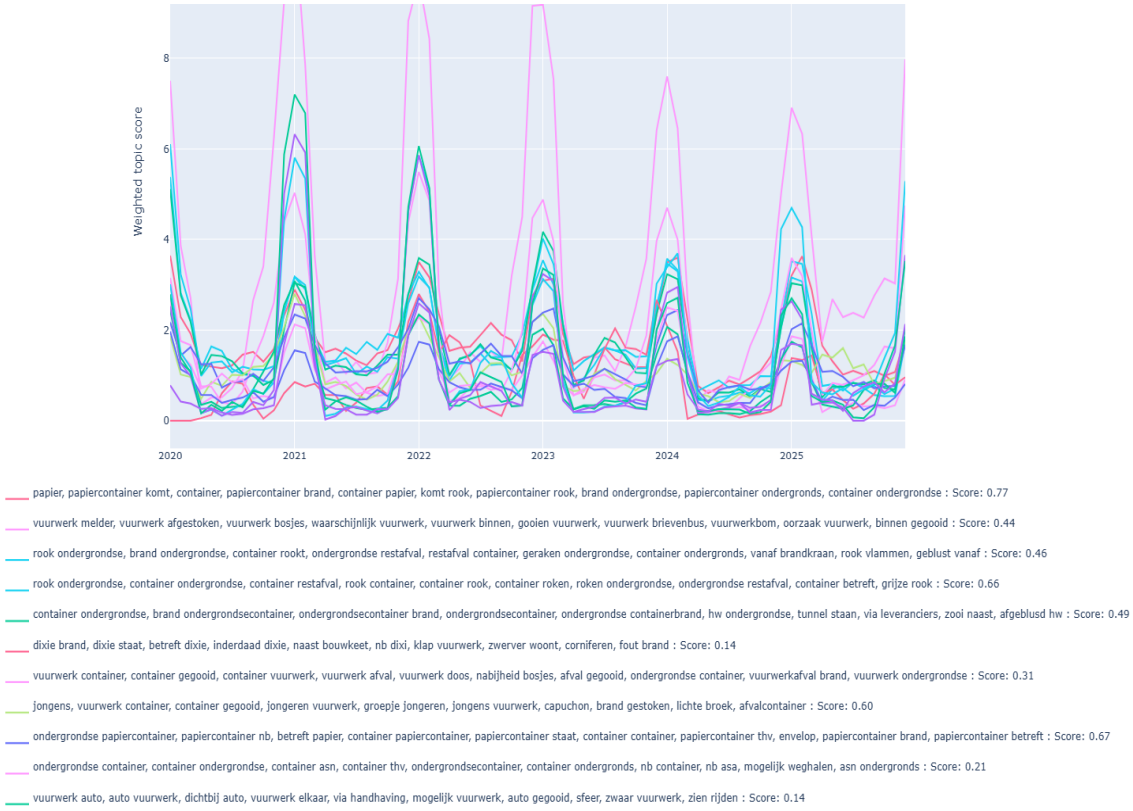
[17] KNMI - September 2020.
[18] KNMI - Augustus 2022.
[19] KNMI - Juni 2023.
[20] KNMI - Mei 2025.



Figuur 3.35 Seizoeneffect: droogte en natuurbranden

Jaarwisseling

Een jaarlijks terugkerende vraag binnen de VR's is wat de impact van de jaarwisseling is op het aantal incidenten. Om dit te onderzoeken zijn meerdere jaarwisselingsgerelateerde topics gezamenlijk geanalyseerd. De jaarwisselingsgerelateerde topics zijn hierbij niet vooraf op basis van een formele selectieprocedure vastgesteld. Wel zijn op basis van de inhoudelijke interpretatie van de gegenereerde topicbeschrijvingen topics geselecteerd die naar verwachting verband houden met de jaarwisseling. Hierbij is met name gekeken naar topics waarin vuurwerk, containerbranden en auto- of autobandenbranden naar voren kwamen. Wanneer de ontwikkeling van deze topics in de tijd over elkaar heen wordt geplot (Figuur 3.36), ontstaat een duidelijk en consistent patroon. Het gaat hierbij om vijf topics over containerbranden (waaronder ondergrondse containers), zes topics over vuurwerk en jongeren en drie topics over auto- en autobandenbranden. In vrijwel alle jaren is in december een sterke piek zichtbaar. Het feit dat al deze topics dezelfde pieken laten zien, suggereert dat, ondanks hun inhoudelijke verschillen, de betreffende incidenten tijdens de jaarwisseling gelijktijdig toenemen. De topicmodellering laat daarmee zien dat de jaarwisseling een duidelijk herkenbaar seizoenseffect heeft op meerdere typen brandgerelateerde incidenten.



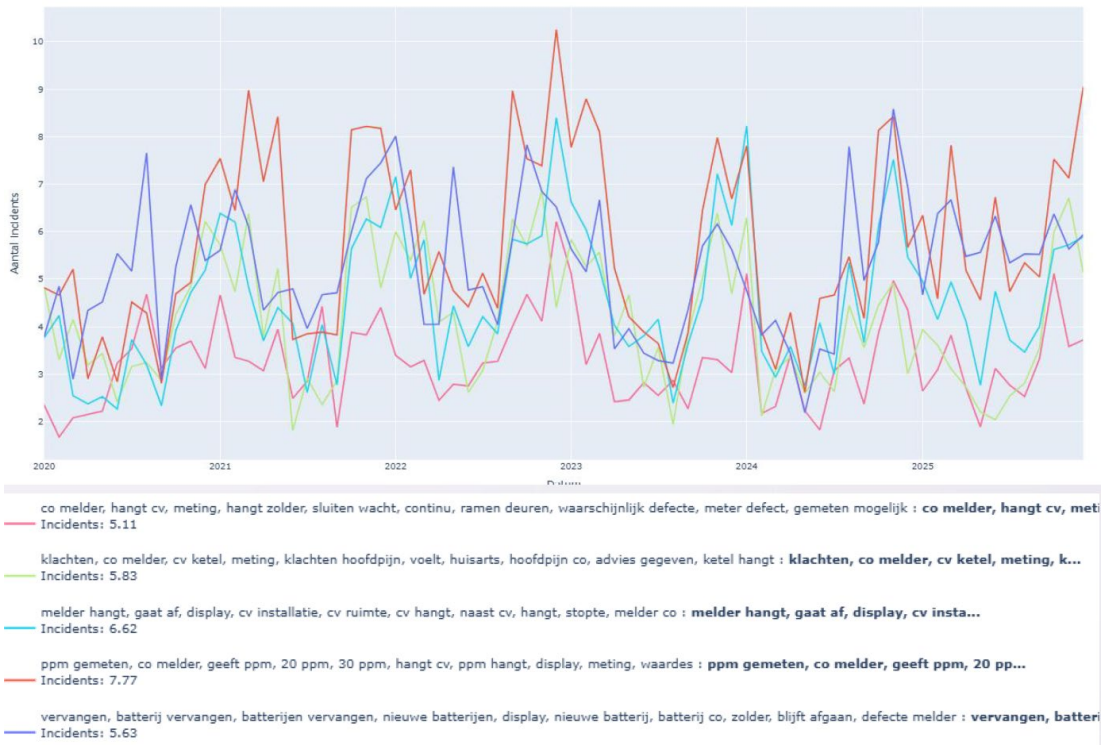
Figuur 3.36 Jaarwisselingsgerelateerde topics en hun verloop over de tijd

CO en seizoenswerking

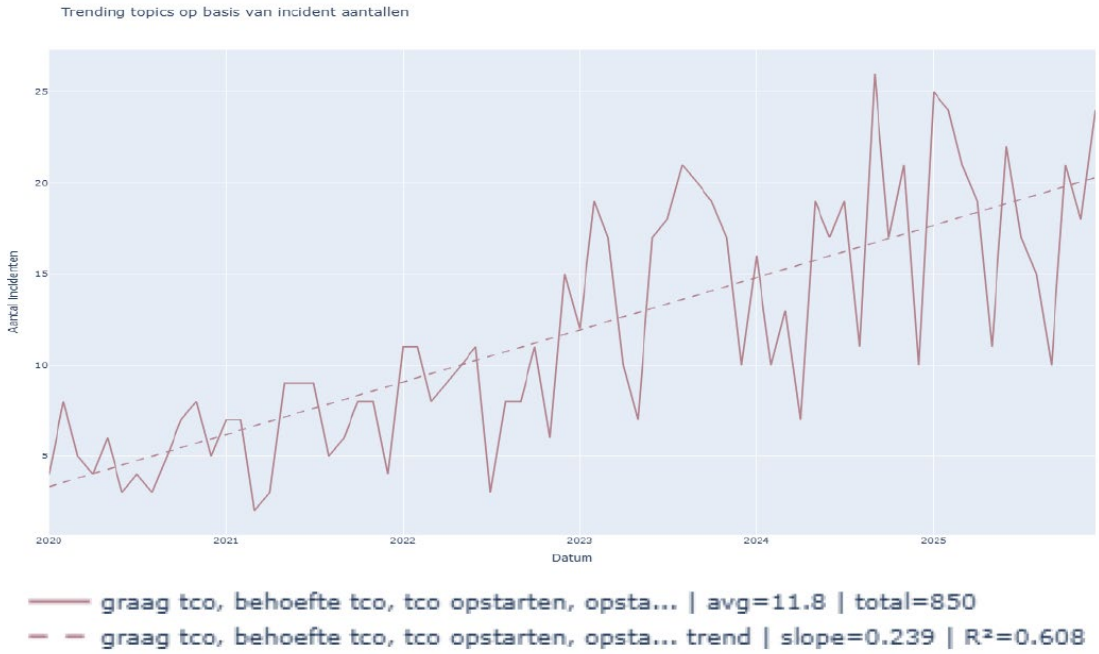
Opvallend binnen de topics is dat een aantal specifiek betrekking heeft op CO-meldingen (Figuur 3.37). Een van deze topics lijkt zelfs te gaan over CO-melders waarvan de batterijen vervangen moeten worden, waardoor een signaal wordt afgegeven. In een ander topic worden expliciet PPM-waarden genoemd, wat zou kunnen duiden op daadwerkelijke metingen van koolmonoxide (dit is echter niet gevalideerd). Hoewel deze topics gezamenlijk het CO-thema delen, verschillen zij in context en inhoud. Daarnaast valt in de bijgevoegde grafiek een duidelijk seizoenspatroon op. Vanaf het najaar neemt het aantal incidenten toe, waarna dit in het voorjaar weer afneemt. Dit patroon is consistent met wat verwacht kan worden bij CO-meldingen, die vaak samenhangen met het stookseizoen.

Team collegiale ondersteuning (TCO)

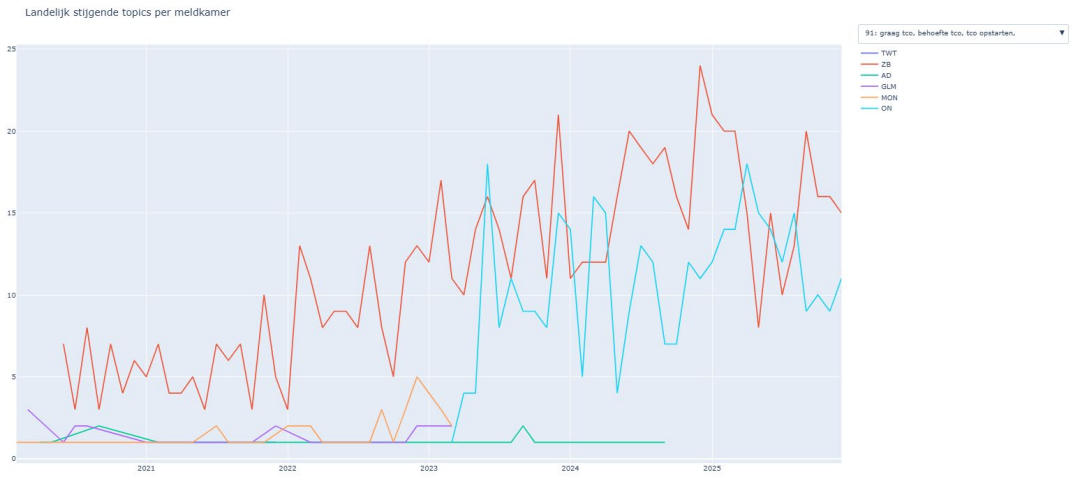
Tijdens de analyse is onderzocht welke significante trends in de data aanwezig zijn. Hierbij is opnieuw enige ruis zichtbaar tussen de verschillende topics. Desondanks valt één topic duidelijk op, namelijk de inzet van TCO (Figuur 3.38). Binnen VRMWB wordt TCO de afgelopen jaren steeds vaker ingezet, mede als gevolg van een herintroductie in 2022. Dit is terug te zien in het betreffende topic, dat inmiddels uit de landelijke data is gefilterd. Om dit verder te onderzoeken, is een aparte grafiek (Figuur 3.39) opgesteld, waarin de aantallen per meldkamer zijn uitgesplitst. Hieruit blijkt dat het TCO-topic voornamelijk voorkomt in de data van VRMWB en meldkamer ON. Op deze manier wordt inzichtelijk hoe specifieke topics zich verdelen over de verschillende meldkamers en waar de incidenten voornamelijk vandaan komen.



Figuur 3.37 CO-gerelateerde topics over de tijd



Figuur 3.38 Inzet van het Team Collegiale Ondersteuning (TCO) over de tijd



Figuur 3.39 Inzet van het Team Collegiale Ondersteuning (TCO) over de tijd: aantallen per meldkamer

Accubranden

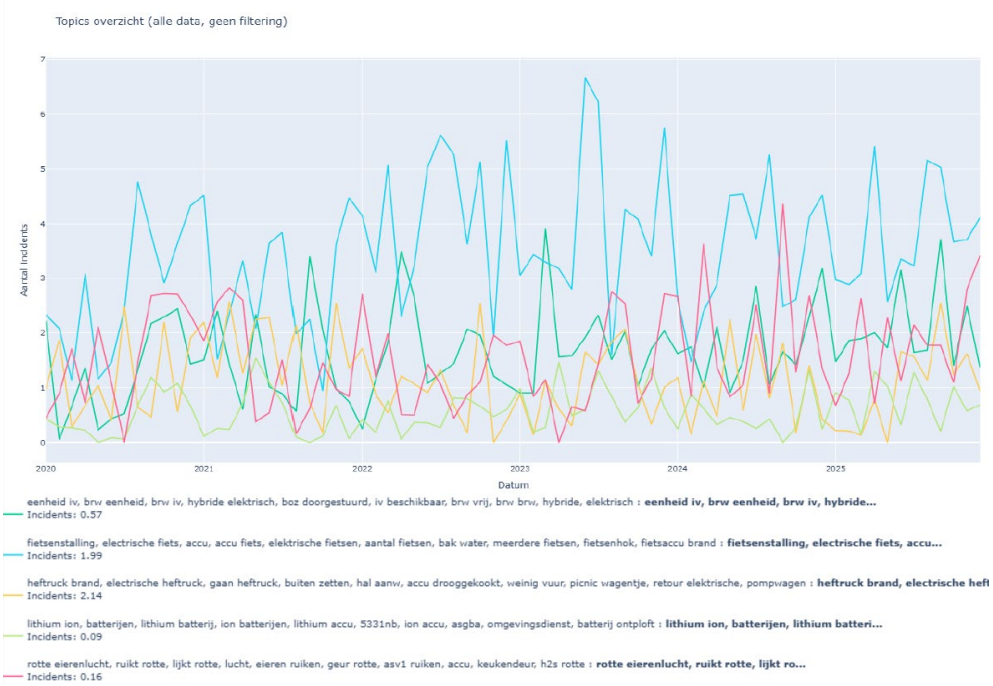
De brandweer krijgt over de tijd te maken met nieuwe incidenttypen. Een recent voorbeeld hiervan is de sterk toename in het gebruik van accu's en incidenten die hieruit voort kunnen komen. Er gaat tijd overheen voordat nieuwe incidenttypen een eigen karakteristiek of classificatie in de data krijgen. Hiervoor moeten ze eerst voldoende worden opgemerkt. Data-analyse zou hierin ondersteunend kunnen zijn. We vroegen ons daarom af of het mogelijk is om nieuwe incidenttypen die nog relatief weinig voorkomen al te ontdekken in de data, met de accubrand als voorbeeld.

Er zijn topics die direct te relateren zijn aan accu’s. Een aantal topics die gevormd zijn over accu’s is geplot in Figuur 3.40. Dit betreft verschillende soorten accu’s en toepassingen. Het aantal incidenten is laag en we zien nog geen duidelijke stijgende lijn. Toch is er een zeer voorzichtige stijging te zien in de topics hybride elektrisch (turquoise), fietsaccu’s (lichtblauw) en rotte eierenlucht (roze).

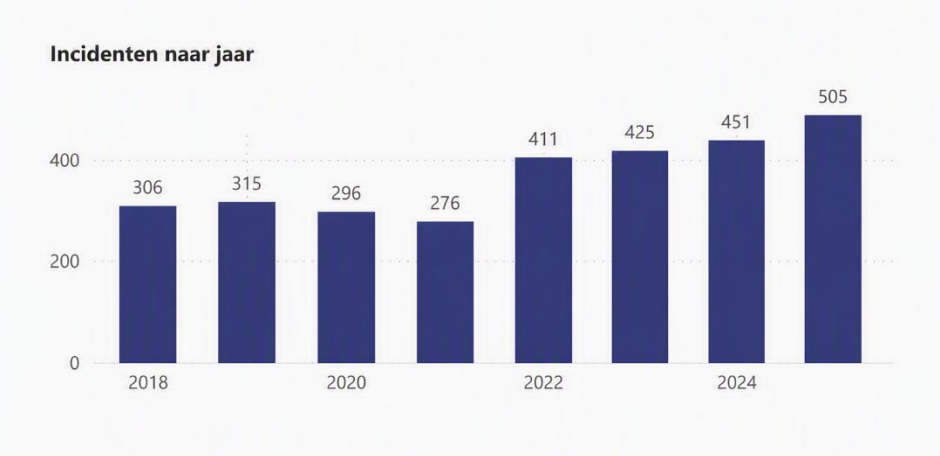
Liftopsluitingen

Binnen VRMWB is in de afgelopen jaren een sterke stijging zichtbaar in het aantal liftopsluitingen. Dit fenomeen is in meerdere andere VR’s bekend. Liftopsluitingen worden al geruime tijd structureel geregistreerd, omdat het GMS hiervoor een specifieke classificatie bevat. Dit maakt het mogelijk om de resultaten uit topicmodellering beter te vergelijken met de officieel geregistreerde incidentcategorieën. VRMWB heeft de aantallen liftopsluitingen in kaart gebracht om deze ontwikkeling nader te kunnen analyseren (Figuur 3.41).

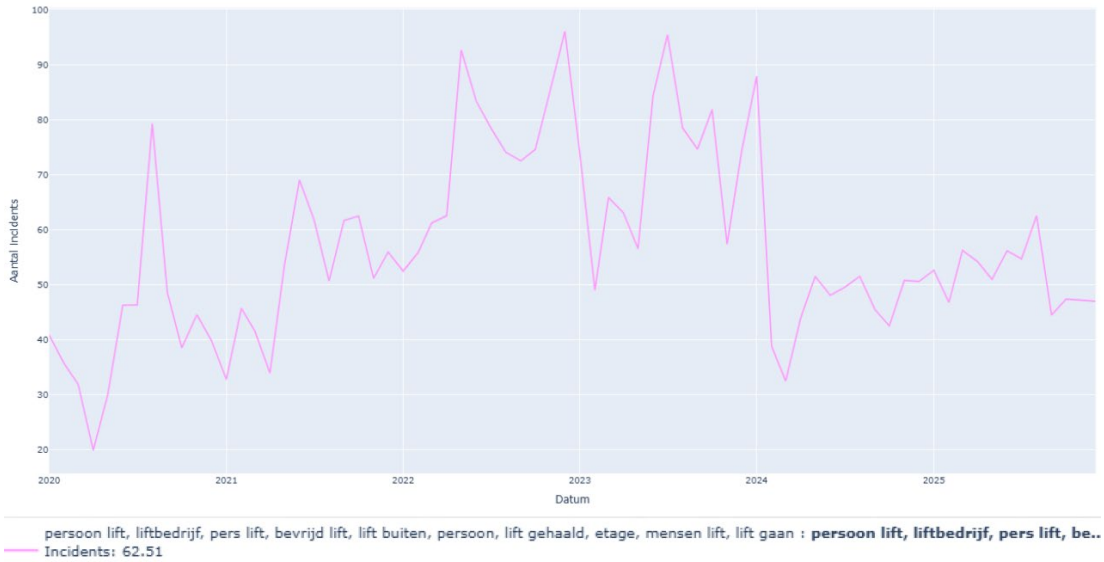
Er is een topic geïdentificeerd dat betrekking heeft op liften en liftopsluitingen. Opvallend is dat de bijbehorende grafieken een vergelijkbare vorm vertonen (Figuur 3.42). In beide datasets is vanaf circa 2021 een duidelijke toename zichtbaar. Waar echter binnen VRMWB vanaf begin 2026 een afname wordt waargenomen, is deze landelijke daling al wat eerder zichtbaar, namelijk vanaf 2024/2025. Hieruit blijkt dat dit patroon niet alleen lokaal binnen VRMWB voorkomt, maar ook terug te zien is in de landelijke data, wat duidt op een bredere, structurele ontwikkeling.



Figuur 3.40 Overzicht van topics gerelateerd aan accubranden over de tijd



Figuur 3.41 Aantal liftopsluitingen in VRMWB over de jaren 2018 - 2025



Figuur 3.42 Topics gerelateerd aan liftopsluitingen over de tijd

3.9.4 Conclusie

Deze trendanalyse biedt inzicht in het ontstaan van, het voorkomen en het verdwijnen van incidenttypen. Een dergelijke methode kan daarom worden ingezet om in een vroeg stadium nieuwe incidenttypen te identificeren. Dit heeft als voordeel dat de ontwikkeling van handelingsperspectieven voor bestrijding van nieuwe incidenttypen al in een eerder stadium gestart kan worden.

Het model is in staat een zeer diverse topics te extraheren uit de data van de deelnemende veiligheidsregio's. Sommige topics geven direct een goed inzicht of laten een duidelijk (al dan niet verwacht) patroon zien. Voorbeelden hiervan zijn liftopsluitingen, CO-meldingen, gaslekkages, natuurbranden en jaarwisselingsgerelateerde incidenten. De ontwikkelingen die binnen deze topics zichtbaar worden, sluiten in veel gevallen aan bij bekende operationele ervaringen en reeds waargenomen trends binnen de VR's. Daarnaast blijkt dat de methode ook onderwerpen kan identificeren die niet of slechts beperkt via reguliere registratiesystemen beschikbaar zijn. Hierdoor kunnen specifieke werkzaamheden, fenomenen of nieuwe ontwikkelingen zichtbaar worden die anders verborgen blijven in de ongestructureerde tekst van kladblokregels. Dit vergroot de informatiepositie van VR's en biedt mogelijkheden om ontwikkelingen vroegtijdig te signaleren.

Een belangrijke meerwaarde van de analyse is dat er niet vooraf hoeft te worden bepaald naar welke onderwerpen gezocht wordt. Het model zoekt zelfstandig naar semantische overeenkomsten in de data en groepeert deze tot onderwerpen. Hierdoor kunnen zowel bekende als onverwachte thema's naar voren komen. In de resultaten zijn hiervan meerdere voorbeelden gevonden, waaronder onderwerpen die op voorhand niet expliciet waren meegenomen in de onderzoeksvraag. Tegelijkertijd laat de analyse zien dat niet elk topic dezelfde mate van bruikbaarheid heeft. Sommige topics zijn zeer specifiek en direct interpreteerbaar, terwijl andere een verzameling van gerelateerde onderwerpen bevatten die minder eenvoudig te duiden zijn. Interpretatie van resultaten door experts is daarom belangrijk. Desondanks tonen de resultaten aan dat topicmodellering een effectieve methode is om grote hoeveelheden ongestructureerde meldkamerdata terug te brengen tot een overzichtelijke verzameling thema's en ontwikkelingen. De onderzoeksvraag kan daarmee

deels bevestigend worden beantwoord. Op basis van de uitgevoerde trendanalyse blijkt het mogelijk om bruikbare patronen, seizoenseffecten en ontwikkelingen te identificeren in ongestructureerde kladblokregels uit meerdere VR's. De gevonden topics vormen daarmee een waardevolle basis voor verdere analyse, signalering en monitoring van incidentgerelateerde ontwikkelingen binnen de VR's.

Wat opvalt is dat er veel topics worden gevonden die niet echt informatief zijn om inzicht te krijgen in incidenttypen. Dit komt doordat de kladblokregels veel teksten, terugkomende woorden en domeintermen bevatten, die niet direct informatie geven over het incident. De variatie tussen VR's is ook nog groot. In de ene VR worden immers andere woorden of specifieke zinnen, afkortingen en zinsstructuren gebruikt dan in andere VR's. Dit heeft effect op het vormen van topics. Door de 'unsupervised' aard van het onderliggende algoritme kan het daardoor voorkomen dat sommige topics vooral regiospecifiek zijn. Daarnaast bevinden zich systeemkladblokregels in de data die vanuit externe systemen en plug-ins, al dan niet automatisch, aan GMS worden toegevoegd. Deze regels zijn niet altijd eenvoudig te herkennen: waar sommige systeemregels op basis van een vast format of herkenbare elementen kunnen worden gefilterd, bevatten andere uitsluitend inhoudelijke informatie zonder duidelijke kenmerken van een externe herkomst. Hierdoor kunnen deze regels moeilijk van reguliere kladblokregels worden onderscheiden en ruis veroorzaken in de topicmodellering.

De grootste beperking op dit moment is het duiden van de topics. Omdat 'onder de motorkap' de topics worden gevormd, op basis van semantische gelijkheid in vectoren, is het niet duidelijk waarom de betreffende teksten bij elkaar geclusterd zijn. Sommige topics lijken specifiek of eenvoudig te duiden, omdat de termen een sterke richting geven; andere doen dat minder. Daarnaast zijn er thema's waaruit meerdere clusters zijn gekomen, waarbij het verschil tussen deze, op het oog gelijke clusters niet duidelijk is. Met een lokaal Ollama model (LLM) is geprobeerd de topics te duiden op basis van de 'representative docs' (de teksten die het belangrijkst zijn geweest voor het vormen van het cluster). Dit is tot op dit moment nog niet gelukt.

Een belangrijk onderdeel van deze analyse is de validatie van de gevonden topics en patronen. De resultaten laten zien dat verschillende onderwerpen die bekend zijn binnen de VR's daadwerkelijk terugkomen in de topicmodellering. Tegelijkertijd heeft in dit onderzoek nog geen formele validatie plaatsgevonden van de volledigheid en juistheid van de gevonden topics. Hoewel bepaalde clusters inhoudelijk herkenbaar zijn, is niet vastgesteld welk aandeel van alle betreffende incidenten daadwerkelijk binnen deze topics is opgenomen. Het is mogelijk dat vergelijkbare incidenten over meerdere topics zijn verdeeld of door het model als ruis zijn aangemerkt. Hierdoor kan een topic wel representatief zijn voor een fenomeen, maar niet noodzakelijk volledig. Ook is niet onderzocht in hoeverre incidenten binnen een topic daadwerkelijk allemaal betrekking hebben op hetzelfde onderwerp. Een topic kan bijvoorbeeld hoofdzakelijk bestaan uit gaslekkages, maar tegelijkertijd ook incidenten bevatten die inhoudelijk minder goed aansluiten. De precisie en compleetheid van de topics zijn daardoor op dit moment onbekend. Voor toekomstig gebruik is het daarom wenselijk om een aanvullende validatiestap uit te voeren. Hierbij kan een steekproef van incidenten handmatig worden beoordeeld door domeinexperts en worden vergeleken met bestaande classificaties binnen GMS. Op die manier kan inzicht worden verkregen in zowel de volledigheid (recall) als de zuiverheid (precision) van de gevonden topics. Ondanks deze beperkingen tonen de resultaten aan dat topicmodellering een

waardevolle aanvulling kan zijn op bestaande informatievoorziening en analyses binnen VR's. De methode is in staat patronen zichtbaar te maken die anders verborgen zouden blijven in grote hoeveelheden ongestructureerde tekst en biedt daarmee een veelbelovende basis voor verdere ontwikkeling en validatie.

Een belangrijke keuze binnen dit onderzoek was het gebruik van samengevoegde kladblokregels per incident als analyse-eenheid. Hierdoor werd alle beschikbare tekst die betrekking heeft op één incident gecombineerd tot één document. Het voordeel hiervan is dat meer context beschikbaar komt voor het model, waardoor de semantische betekenis van een incident beter kan worden vastgelegd. Korte en relatief weinig informatieve kladblokregels krijgen hierdoor meer samenhang en zijn eenvoudiger te clusteren. Tegelijkertijd kent deze keuze ook beperkingen. Binnen één incident kunnen meerdere onderwerpen of fenomenen voorkomen. Een melding kan bijvoorbeeld starten als een automatische brandmelding, waarna later informatie wordt toegevoegd over een industriebrand of een andere ontwikkeling binnen het incident. Tijdens het vormen van de topics wordt het incident echter als één document beschouwd. Hierdoor bestaat het risico dat één dominant onderwerp de clustering bepaalt, terwijl andere relevante aspecten minder zwaar meewegen of zelfs geheel buiten beeld blijven.

Om dit gedeeltelijk te ondervangen is na de initiële topicmodellering een aanvullende stap uitgevoerd waarbij alle gevonden topics opnieuw zijn gematcht met alle incidenten. Hierdoor kunnen meerdere topics aan hetzelfde incident worden gekoppeld. Deze aanpak vermindert het probleem dat een incident slechts aan één onderwerp wordt gekoppeld en maakt het mogelijk om meerdere fenomenen binnen een incident te herkennen. Deze aanpak lost echter niet volledig het onderliggende probleem op. Wanneer relevante informatie tijdens de vorming van de topics onvoldoende vertegenwoordigd is geweest, kan een specifiek fenomeen alsnog niet als afzonderlijk topic ontstaan. Met andere woorden: de aanvullende matching kan bestaande topics beter koppelen aan incidenten, maar kan geen onderwerpen terughalen die tijdens het clusteringproces al verloren zijn gegaan.

Een alternatief is het uitvoeren van topicmodellering op het niveau van individuele kladblok-regels. Hierdoor worden kleinere en specifiekere tekstfragmenten geanalyseerd, waardoor afzonderlijke fenomenen mogelijk beter zichtbaar worden. Daar staat tegenover dat veel kladblokregels weinig context bevatten, wat kan leiden tot meer ruis en minder stabiele clustering. Op dit moment is niet onderzocht welke benadering het meest geschikt is. Vervolgonderzoek zou kunnen uitwijzen in hoeverre de keuze voor incident- of regelniveau invloed heeft op de kwaliteit, volledigheid en interpretatie van de gevonden topics.

In dit onderzoek zijn de kladblokgegevens van meerdere VR's samengevoegd tot één landelijke dataset. Het voordeel hiervan is dat het model kan leren van een grote hoeveelheid data en landelijke trends zichtbaar kunnen worden. Omdat er meer data beschikbaar is, zullen patronen ook sneller zichtbaar worden dan wanneer slechts de data van één regio worden gebruikt. Tegelijkertijd brengen VR's onderlinge verschillen met zich mee. Niet iedere meldkamer gebruikt dezelfde terminologie, afkortingen of werkwijzen bij het vastleggen van informatie. Hierdoor bestaat de kans dat topics ontstaan die vooral het taalgebruik van een specifieke regio weerspiegelen in plaats van een daadwerkelijk operationeel fenomeen. Ook kunnen vergelijkbare incidenten uit verschillende regio's in afzonderlijke topics terechtkomen, doordat ze anders worden beschreven.

Deze analyse heeft laten zien dat het mogelijk is om trends in incidenttypen over tijd te identificeren en zo ook nieuwe incidenttypen te identificeren. Voor toepassing in de praktijk is het wenselijk dat deze analyse op landelijke data kan worden gedaan, omdat dit sneller tot identificatie zal leiden dan regionale toepassing. Ook is het belangrijk om te werken aan verdere uniformering van de data, zodat topics ook op een goede manier gebundeld worden in de analyse.

3.10 Opschalingvoorspelling

3.10.1 Inleiding

Gebouwbrandincidenten kunnen zich tijdens de inzet op uiteenlopende manieren ontwikkelen. Hoewel bij de eerste melding en uitruk al een inschatting wordt gemaakt van de aard en omvang van een gebouwbrand, kan de werkelijke situatie ter plaatse soms anders zijn dan verwacht. Nadat de bevelvoerder de situatie heeft verkend, kan aanvullende informatie over de brand, het gebouw en de omgeving aanleiding geven om op te schalen. Beter inzicht krijgen in de factoren die met opschaling samenhangen, kan bijdragen aan een soepeler incidentverloop. Daarbij biedt de informatie die op het moment van opschalen al bekend is mogelijk aanknopingspunten om de noodzaak tot opschaling eerder te herkennen, te voorspellen en daarop te anticiperen. Het doel van dit onderzoek is om uit te zoeken welke incident- en contextkenmerken samenhangen met opschaling bij gebouwbranden, nadat de bevelvoerder ter plaatse is gekomen. Daarbij wordt onderzocht in hoeverre opschaling kan worden verklaard en voorspeld op basis van de tot dat moment beschikbare gegevens.

3.10.2 Methode

Data

Voor deze analyse zijn twee databronnen gecombineerd op incidentniveau: 1) GMS-data met incidentgegevens (onder andere meldingsdatum, meldingsclassificatie, prioriteit, VR), voertuiggegevens (tijdstempels van alarmering tot en met op kazerne, voertuigsoort / tankautospuit) en karakteristieken (onder andere Ops Br: operationele omvangsbepaling van de brand), en 2) BAG-data met gebouweigenschappen van de incidentlocatie (bouwjaar, gebruiksoppervlakte, gebruiksdoel, aantal verblijfsobjecten per pand, pandhoogte). De gebruikte data besloegen de jaren 2020 tot en met 2025 en hadden betrekking op alle zeven VR's die data hadden aangeleverd. Verschillen in opschalingsproces en -gedrag tussen VR's konden daarmee bestudeerd worden. Deze bronnen zijn samengevoegd tot één analysebestand met bijbehorende tankautospuit- en gebouwkenmerken. Incidentdata werden gefilterd op gebouwbranden met daadwerkelijke inzet en met de hoogste mate van urgentie (prioriteitscode 1), aangezien het opschalingsgedrag alleen relevant is om te bestuderen bij incidenten waarbij daadwerkelijk met de hoogste prioriteit is uitgerukt.

Definities

Opschaling werd in dit onderzoek gedefinieerd op basis van tankautospuitinzet. Incidenten zonder deze gegevens konden niet in de opschalingsanalyse worden meegenomen. Opschaling op basis van de tankautospuitinzet werd bepaald aan de hand van het aantal ingezette tankautospuiten en het moment waarop een tweede tankautospuit werd gealarmeerd ('geen opschaling' = 1 TS; 'opschaling_start_incident' = TS 1 en TS 2 gelijktijdig gealarmeerd; 'opschaling_voor_tp' = 2e TS gealarmeerd vóór ter plaatse komst 1e TS; 'opschaling_na_tp' = 2e TS gealarmeerd na ter plaatse komst 1e TS); 'opschaling_onbekend' = ter plaatse tijd 1e TS ontbreekt).

Inclusie en exclusies
Over de periode 2020-2025 waren er 245.061 initieel geladen incidenten in GMS. Twee incidenten zonder geldige meldingsdatum werden verwijderd, aangezien deze onbruikbaar waren voor tijdsberekeningen. Er werden drie dubbele incidentnummers in de brondata aangetroffen. Vanwege het zeer beperkte aantal dubbelen zijn ze voor deze analyse uit de data verwijderd. Van de 245.059 overgebleven incidenten voldeden 18.059 incidenten aan de definitie 'gebouwbrand prioriteit 1'. Vervolgens zijn alleen de incidenten met minimaal één gekoppelde tankautospuitinzet behouden (inner join). Dit resulteerde in 18.039 gebouwbranden (prioriteit 1) met bijbehorende tankautospuit- en gebouwkenmerken. Vanwege verschil in procedures tussen VR's zijn de data van de VRT en VRAA niet meegenomen in deze analyse en bestond de uiteindelijke dataset uit 11947 incidenten.

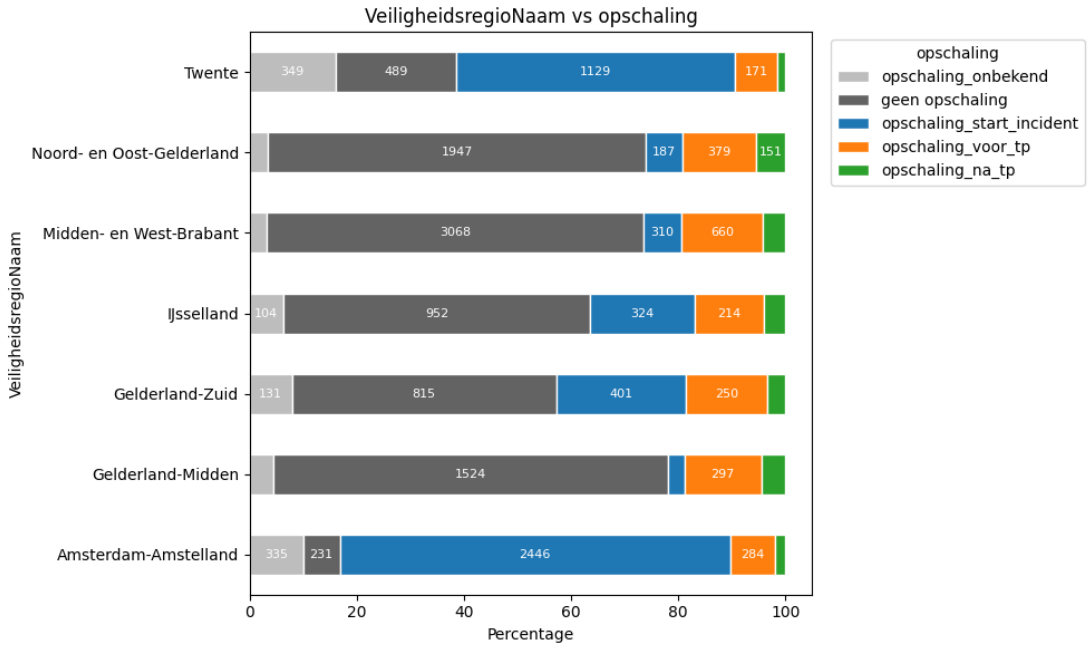
Analyse
Voor het voorspellen van opschaling bij brandincidenten is gebruikgemaakt van logistische regressie, waarbij de modellen werden getraind met alle data uit de periode 2020-2024 en getest op de 2025-dataset. Categorische variabelen werden omgezet naar dummy variabelen (regio, maand, nacht versus dag, bouwperiode van het gebouw, type gebouw, relatieve oppervlakte van het gebouw, hoogte van het gebouw). Er zijn drie afzonderlijke logistische regressiemodellen ontwikkeld, elk met een eigen definitie van de uitkomstvariabele:

1. geen opschaling (0) versus wel opschaling (1). Opschaling is gedefinieerd als het aantal gealarmeerde tankautospuiten > 1.
2. geen opschaling (0) versus opschaling na ter plaatse bevelvoerder (1). Het moment waarop de bevelvoeder ter plaatse was, is gedefinieerd als de tijd waarop de eerste tankautospuit ter plaatste kwam. Voor deze analyse is ook gecorrigeerd voor class imbalance (Scikit Learn, 2026), waarbij het model meer gewicht geeft aan de zeldzame klasse (klasse 1) en minder aan de veelvoorkomende klasse (klasse 0).
3. geen opschaling of opschaling bij start incident (0) versus opschaling voor of na ter plaatse (1). Voor deze analyse is ook gecorrigeerd voor class imbalance.

Alle analyses zijn uitgevoerd in Python 3.12.6 en er is gebruikgemaakt van de library sklearn. De code is beschikbaar op Gitlab (Gitlab, DATAPRO112 – 05 inzet en opschaling, z.d.).

3.10.3 Resultaten
De uiteindelijk gebruikte data bevatten 18.039 gebouwbranden met prioriteit 1. Figuur 3.43 geeft een overzicht van de opschaling per regio. Hierin zien we grote verschillen in het proces van opschaling tussen VR's. In VRAA en VRT worden TS1 en TS2 in de meeste gevallen al gelijktijdig gealarmeerd (met blauw aangegeven in de figuur). De overige regio's schalen in de meeste gevallen niet op met een tweede TS (donkergrijs). Er is slechts een klein aantal incidenten waarbij pas na het ter plaatse komen van de bevelvoerder wordt opgeschaald (groen); de opschaling vindt bijna altijd plaats bij de start van het incident of wanneer de eerste TS nog aanrijdend is.

Vanwege de grote verschillen in procedures tussen VRT en VRAA met de overige VR's, is besloten om data van VRT en VRAA te excluderen van de uiteindelijke analyse. Zonder deze regio's worden er in totaal 11.947 incidenten meegenomen in de regressiemodellen.



Figuur 3.43 Verdeling van opschaling onder incidenten per regio

Performance van de modellen

Model 1 (geen opschaling vs. opschaling) lijkt redelijk te presteren in het herkennen van ‘geen opschaling’ (precision 0.76, recall 0.90) maar niet goed in het herkennen van ‘opschaling’ (precision 0.52, recall 0.28). Dit betekent dat de voorspellers in het model (gebouwkenmerken, tijd, VR) niet goed kunnen onderscheiden wanneer er sprake is van opschaling en wanneer niet. Model 2 (geen opschaling vs. opschaling na ter plaatse bevelvoerder) laat vergelijkbare resultaten zien: het presteert redelijk in het herkennen van ‘geen opschaling’ (precision 0.96, recall 0.68) maar slecht in het herkennen van ‘opschaling’ (precision 0.07, recall 0.45). Model 3 dat (geen opschaling/opschaling bij start incident vs opschaling voor/na ter plaatse) presteert matig in het herkennen van ‘geen opschaling / opschaling bij start incident’ (precision 0.84 en recall 0.60) en slecht in het herkennen van ‘opschaling voor / na ter plaatse’ (precision 0.21 en recall 0.48).

3.10.4 Conclusie en discussie

In dit onderzoek is onderzocht in hoeverre opschaling van gebouwbrandincidenten kan worden voorspeld met behulp van logistische regressie. Het bleek dat de gebruikte modellen slechts beperkt in staat waren om onderscheid te maken tussen incidenten die wel en niet zouden worden opgeschaald.

De resultaten laten zien dat het aantal incidenten waarbij een tweede TS wordt gealarmeerd nadat de bevelvoerder ter plaatse is gekomen, zeer beperkt is. In de meeste gevallen vindt de opschaling al in een eerder stadium plaats. Dit houdt dus ook in dat het moment waarop de bevelvoerder ter plaatse aanvullende informatie verzamelt, slechts in een minderheid van de gevallen leidt tot verdere opschaling. Deze resultaten suggereren dan ook dat er voor de VR’s relatief weinig winst te behalen valt met het voorspellen van opschaling die pas plaatsvindt nadat de bevelvoerder ter plaatse is gekomen. Een andere belangrijke bevinding is dat er grote verschillen bestaan tussen VR’s in de wijze waarop het opschalingsproces is ingericht. Hierdoor zijn de gevonden relaties tussen incidentkenmerken en opschaling sterk afhankelijk van de regionale context. De resultaten bieden mogelijk aanknopingspunten voor

vervolgonderzoek naar de factoren die ten grondslag liggen aan de huidige regionale verschillen in procedures.

Dit onderzoek kent een paar beperkingen. Ten eerste is gebruikgemaakt van een beperkte selectie voorspellers. Mogelijk relevante factoren, zoals karakteristieken en buurtkenmerken, verschillen tussen centralisten en bevelvoerders of verschillen tussen beroeps- en vrijwillige posten, zijn niet meegenomen. Ten tweede is gekozen voor een relatief eenvoudige definitie van opschaling. Opschaling is alleen bepaald aan de hand van het aantal gealarmeerde TS en daarbij is alleen onderscheid gemaakt tussen één TS en meer dan één TS. Ook eventuele gradaties in opschaling zijn buiten beschouwing gelaten.

Samenvattend laat dit onderzoek zien dat opschaling van gebouwbrandincidenten met de gebruikte gegevens niet goed voorspelbaar is en dat opschaling na aankomst van de bevelvoerder maar relatief weinig voorkomt. Er is meer uniformiteit nodig in incidentdata, definitie en opschalingsprocessen, voordat een landelijk voorspelmodel ontwikkeld kan worden.

4 Conclusies

Binnen DATAPRO112 zijn incidentgegevens uit verschillende bronnen samengebracht en geanalyseerd. Het doel was om hiermee meer inzicht te krijgen in het huidige 112-incidentafhandelingsproces en in de mogelijkheden om data science toe te passen ter ondersteuning van besluitvorming. De beschikbare data bieden goede aanknopingspunten voor verdere analyses, monitoring en kennisontwikkeling, maar door verschillen in registratie en werkwijze tussen VR's en meldkamers kunnen de data op dit moment niet optimaal worden benut. Een belangrijke bevinding is dat we met een trendanalyse in staat zijn om nieuwe incidenttypen te identificeren. Implementatie van een dergelijke toepassing in de praktijk kan een meerwaarde bieden voor de incidentbestrijding. Maar om optimaal gebruik te kunnen maken van datatoepassingen is het belangrijk dat de data verder worden geüniformeerd en de datakwaliteit wordt verbeterd.

Uit de interviews blijkt dat het 112-incidentafhandelingsproces in de basis overeenkomt tussen de onderzochte regio's, wat mogelijkheden biedt voor het samenvoegen van de data en het gezamenlijk ontwikkelen van datatoepassingen. Tegelijkertijd bestaan er verschillen in de wijze waarop informatie wordt geregistreerd, welke gegevens worden vastgelegd en welke ondersteunende systemen worden gebruikt. Variatie in definities, registratiewijzen en datastructuur maakt de de vergelijking van resultaten en de ontwikkeling van breed toepasbare data-science-modellen nog moeilijk. Ook is het GMS gericht op primaire ondersteuning en is het niet ontwikkeld voor analytische doeleinden. Dit zorgt ervoor dat de data die uit GMS voortkomen niet altijd eenvoudig te combineren en te analyseren. Vergelijkingen tussen veiligheidsregio's zijn weliswaar mogelijk, maar de uitkomsten zijn niet altijd gemakkelijk te interpreteren. Hiervoor is een goed begrip nodig van zowel de processen waarin de data worden verzameld als van de regionale context. Verschillen tussen veiligheidsregio's lijken bijvoorbeeld deels samen te hangen met regionale kenmerken, zoals de verhouding tussen beroeps- en vrijwillige brandweerposten. Verder suggereren de resultaten dat het gebruik van karakteristieken tussen regio's relatief vergelijkbaar is, terwijl de geregistreerde waarden en aanvullende informatie meer regionale verschillen bevatten. Op basis van deze gegevens blijken veiligheidsregio's dan ook nog redelijk goed van elkaar te onderscheiden. Tegelijkertijd laten de analyses uit hoofdstuk 3.9 zien dat veranderingen in de samenstelling van de dataset invloed kunnen hebben op de resultaten. Zo heeft de aansluiting van meldkamer Oost-Nederland vanaf 2023 geleid tot een aanzienlijke toename van de beschikbare data. Hierdoor kunnen waargenomen trends deels worden verklaard door veranderingen in de dataset zelf, in plaats van door daadwerkelijke veranderingen in incidenten. Hierdoor is voorzichtigheid geboden bij het interpreteren van trends en het trekken van conclusies op basis van longitudinale analyses.

Ook blijkt dat veel karakteristieken weinig inhoudelijke of verdiepende informatie over het incident bevatten. In GMS worden verschillende typen informatie onder dezelfde noemer geregistreerd. Zo omvatten karakteristieken zowel procesinformatie (zoals 'brand meester'), als incidentkenmerken (zoals 'schoorsteenbrand'). Omdat deze gegevens een verschillend doel en een verschillende betekenis hebben, beperkt dit de mogelijkheden om incidenten eenduidig te classificeren en te analyseren. Om de data meer geschikt te maken voor analyses, is het nodig om onderscheid te maken tussen systeemkenmerken, proces-

kenmerken en incidentkenmerken. Meer structuur en standaardisatie in de registratie kunnen bijdragen aan een betere vergelijkbaarheid tussen regio's en een diepgaandere analyse van incidenttypen, operationele processen en regionale verschillen.

Een deel van de regionale verschillen wordt veroorzaakt door automatisch toegevoegde informatie uit externe systemen, waarvan het aandeel in de registraties in de loop der jaren is toegenomen. Dit blijkt uit de analyses van kladbloktekst. Wanneer deze systeemgebonden informatie buiten beschouwing wordt gelaten, blijken de registraties van de regio's beter overeen te komen. Dit pleit voor een toepassing waarmee systeemcodes eenvoudig kunnen worden gefilterd, zodat de uniformiteit van de data wordt vergroot en ruis in analyses wordt beperkt. De toepassing van tekst- en data-analysetechnieken blijkt namelijk veelbelovend. Zowel clustering als topicmodellering leverden herkenbare en inhoudelijk betekenisvolle resultaten op. Verschillende topics zoals liftopsluitingen, CO-meldingen, gaslekkages, natuurbranden en jaarwisselingsgerelateerde incidenten kwamen duidelijk naar voren en sloten aan bij bekende operationele ervaringen binnen de VR's.

Tegelijkertijd laat het onderzoek zien dat de mogelijkheden van voorspellende modellen niet onbeperkt zijn. De analyses naar opschaling van gebouwbrandincidenten tonen aan dat dergelijke opschalingen met de huidige gegevens slechts beperkt voorspelbaar zijn. Opschaling na aankomst van de bevelvoerder komt relatief weinig voor en verschillen in definities, registraties en opschalingsprocessen beperken de prestaties van voorspel-modellen. Dit onderstreept wederom dat kwalitatieve, uniforme en landelijk vergelijkbare data een belangrijke voorwaarde vormen voor de ontwikkeling van betrouwbare voorspellende modellen.

Naast de data die in het operationele proces worden verzameld, zijn aanvullende gegevens nodig om werkelijk inzicht te krijgen in incidenten. De analyses hebben aangetoond dat incidentmeldingen niet altijd werkelijke incidenten zijn en dat initiële GMS classificeren ook niet altijd overeenkomen met dat wat de bevelvoerder aantrof op de plaats incident. Ook laten de resultaten zien dat het aantal slachtoffers nog niet goed inzichtelijk kan worden gemaakt op basis van kladblokdata. Omdat data-analyse ook niet het primaire doel is van het GMS, is het nodig om een aanvullende dataverzameling in te richten, bijvoorbeeld in de vorm van een bevelvoerdersvragenlijst, zoals is gedaan in door de VRT.

Bij de interpretatie van de resultaten moet rekening worden gehouden met een aantal belangrijke beperkingen van dit onderzoek. Van de 25 VR's in Nederland hebben er zeven deelgenomen aan dit project. De deelnemende regio's zijn aangesloten bij drie van de tien meldkamers die Nederland telt. Hoewel dit aantal voldoende basis biedt om inzicht te krijgen in het gebruik van incidentdata en de mogelijkheden van data-science-toepassingen, is voorzichtigheid geboden bij het trekken van conclusies over de landelijke situatie.

In de analyses beschreven in hoofdstukken 3.5 en 3.7 is gebruikgemaakt van gegevens uit slimme vragenlijsten. De koppeling tussen deze vragenlijsten en de registraties in GMS bleek niet altijd volledig of eenduidig, waardoor de omvang en kwaliteit van de onderzoeks-populatie werden beperkt. Tegelijkertijd laten de resultaten zien dat de combinatie van vragenlijstgegevens en GMS-registraties waardevolle aanvullende inzichten kan opleveren. Dit biedt perspectief voor toekomstig onderzoek en benadrukt het belang van een bredere en uniformere dataverzameling. Het gebruik van een gestandaardiseerde landelijke slimme vragenlijst kan hieraan een belangrijke bijdrage leveren.

Concluderend laat DATAPRO112 zien dat incidentdata een rijke en veelbelovende bron vormen voor kennisontwikkeling en ondersteuning van de operationele praktijk. Tegelijkertijd blijkt dat verdere stappen nodig zijn op het gebied van standaardisatie, datakwaliteit, inzicht in regionale werkprocessen en aanvullende dataverzameling. Naarmate meer uniformiteit ontstaat in registratie, definities en werkwijzen, nemen de mogelijkheden toe om VR's beter met elkaar te vergelijken, landelijke analyses uit te voeren en data-science-toepassingen effectief in te zetten ter ondersteuning van de besluitvorming binnen het 112-domein.

4.1 Vervolgonderzoek

De resultaten van dit onderzoek bieden verschillende aanknopingspunten voor vervolg-onderzoek. Vervolgonderzoek met een bredere landelijke dekking is noodzakelijk om de generaliseerbaarheid van de bevindingen verder te toetsen.

Hoewel tekstanalyses en clustering relevante patronen blootleggen, is momenteel slechts een beperkt onderscheid te maken tussen informatieve en niet-informatieve tekst in relatie tot de aard van een incident. Hierdoor bestaat het risico dat modellen patronen leren die weinig inhoudelijke betekenis hebben voor incidenttypering. Een logische vervolgstap is daarom het ontwikkelen van methoden waarmee informatieve tekstfragmenten automatisch kunnen worden herkend en gescheiden van administratieve of procedurele informatie. Het toepassen van tekstanalyses op uitsluitend deze informatieve delen kan mogelijk leiden tot beter interpreteerbare resultaten. Daarbij is het aantal regels, termen en woorden in de kladbloktekst per incident doorgaans laag, waardoor ook de hoeveelheid beschikbare informatie per incident beperkt blijft. Voor toekomstig onderzoek is het daarom interessant om aanvullende bronnen en domeinspecifieke kennis expliciet in modellen op te nemen. Hierbij kan bijvoorbeeld worden gedacht aan standaardmeldingen en andere operationeel relevante begrippen die binnen meldkamers worden gebruikt. Het combineren van dergelijke domeinkennis met moderne analysetechnieken biedt mogelijk nieuwe kansen om de informatie uit incidentregistraties beter te benutten en de toepasbaarheid van data science verder te vergroten.

Daarbij heeft dit onderzoek laten zien dat topicmodellering waardevolle inzichten kan opleveren uit ongestructureerde meldkamerdata. Tegelijkertijd heeft het ook duidelijk gemaakt dat er nog verschillende vraagstukken openstaan rondom de interpretatie, validatie en optimalisatie van de methode. Na extra validatie kan er een werkende methode ontstaan waarmee landelijke kladblokdata geanalyseerd kan worden en trends zichtbaar kunnen worden gemaakt. De resultaten laten zien dat zowel bekende als nieuwe fenomenen kunnen worden geïdentificeerd. De huidige resultaten vormen daarmee een startpunt voor verdere doorontwikkeling. Toekomstig onderzoek kan zich richten op het verbeteren van de datakwaliteit, het verder reduceren van systeemgerelateerde ruis en het valideren van topics ten opzichte van bestaande classificaties binnen GMS. Ook verdient het automatisch duiden en labelen van topics verdere aandacht, bijvoorbeeld door de inzet van moderne Large Language Models in combinatie met domeinexperts.

Daarnaast is het interessant om alternatieve benaderingen te onderzoeken, zoals topicmodellering op het niveau van individuele kladblokregels, regionale topicmodellen en hybride benaderingen waarin regionale en landelijke analyses worden gecombineerd. Ook

kan worden onderzocht in hoeverre herhaalde analyses over meerdere jaren in staat zijn om opkomende fenomenen vroegtijdig te signaleren en structurele veranderingen binnen het incidentbeeld zichtbaar te maken. Uiteindelijk ligt de grootste potentie mogelijk niet in een eenmalige analyse, maar in het ontwikkelen van een continu monitoringsinstrument waarmee VR's nieuwe ontwikkelingen kunnen volgen en onderwerpen kunnen identificeren die nog niet structureel worden geregistreerd. De resultaten van dit onderzoek laten zien dat daarvoor een veelbelovende basis aanwezig is en dat verdere ontwikkeling van deze methodiek meerwaarde kan opleveren.

Daarnaast bieden de resultaten aanknopingspunten voor onderzoek naar de relatie tussen de initiële melding, de daaropvolgende inzet en de operationele besluitvorming tijdens incidenten. Meer inzicht in de kenmerken van incidenten die samenhangen met de uiteindelijke afhandeling en uitkomsten kan helpen om inzetstrategieën beter af te stemmen op de daadwerkelijke situatie. Hierdoor kan worden verkend of in bepaalde gevallen met een beperktere eerste inzet een vergelijkbaar resultaat kan worden bereikt, zonder dat dit leidt tot een onacceptabel risiconiveau. Denk bijvoorbeeld aan situaties waarin eerst een verkennend voertuig, een drone of een andere beperkte inzet wordt gestuurd, voordat een volledige tankautospuit uitrukt. Om dergelijke afwegingen op een evidence-based manier te kunnen maken en evalueren, zijn betrouwbare, uniforme en systematisch verzamelde incidentgegevens essentieel.

4.2 Aanbevelingen

Op basis van de resultaten van dit onderzoek worden de volgende aanbevelingen gedaan om de kwaliteit, vergelijkbaarheid en toepasbaarheid van incidentdata verder te vergroten:

1. **Toewerken naar meer landelijke standaardisatie van registraties.**
   Verschillen in definities, registratiepraktijken en werkprocessen beperken de vergelijkbaarheid van data tussen VR's. Meer uniformiteit in de registratie van incidenten, karakteristieken en opschalingen is een belangrijke voorwaarde voor betrouwbare regionale vergelijkingen en landelijke analyses.

2. **Verbeteren van de kwaliteit en bruikbaarheid van GMS-data voor analyses.**
   GMS is primair ingericht ter ondersteuning van de operationele afhandeling van incidenten en minder voor data-analyse. Meer aandacht voor datakwaliteit, volledigheid en consistente vastlegging van gegevens kan de inzet van data-science-toepassingen aanzienlijk versterken.

3. **Beter onderscheid maken tussen systeem-, proces- en incidentinformatie.**
   Een deel van de geregistreerde informatie weerspiegelt vooral gebruikte systemen en lokale werkprocessen in plaats van kenmerken van het incident zelf. Het scheiden van deze informatietypen kan de hoeveelheid ruis in analyses verminderen en leiden tot beter interpreteerbare en beter generaliseerbare modellen.

4. **Data-uitwisseling en gezamenlijke kennisontwikkeling stimuleren.**
   De uitwisseling van incidentgegevens tussen VR's is momenteel beperkt. Een landelijke aanpak biedt kansen om van elkaar te leren, regionale verschillen beter te begrijpen en

gezamenlijk data-science-toepassingen te ontwikkelen die de operationele besluitvorming ondersteunen.

5. **Een Community of Practice Data-science opzetten.**
   De data-scientists van de verschillende organisaties die mee hebben gedaan in DATAPRO112 waren enthousiast over het samen werken aan vraagstukken, omdat deze werkwijze kennisuitwisseling stimuleert en een mogelijkheid geeft om te sparren over dataproblemen en oplossingen.

Samengevat is de belangrijkste aanbeveling om te investeren in uniforme, kwalitatief hoogwaardige en landelijk uitwisselbare data en een samenwerkingsovereenkomst die uitwisseling voor onderzoeks- en ontwikkeldoeleinden mogelijk maakt. Dit vormt de basis voor toekomstige analyses, vergelijkingen tussen regio's en de ontwikkeling van datagedreven ondersteuning binnen het 112-domein.

Literatuur

Brandweer Nederland. (2023). *Programmaplan toekomstbestendige brandweerzorg 2026-2028.* Geraadpleegd op 5 oktober 2026, van GW3-programmaplan-Toekomstige-Brandweerzorg-2026-2028.pdf

Brandweer Nederland. (2023). *Nieuwe meldkamer in Apeldoorn voor 3,3 miljoen inwoners*. Geraadpleegd op 13 juli 2026, van https://www.brandweernederland.nl/nieuws/nieuwe-meldkamer-in-apeldoorn-voor-33-miljoen-inwoners/

CBS. (2026). *Rijbewijs- en autobezit stijgt*. Geraadpleegd op 31 augustus 2026, van https://www.cbs.nl/nl-nl/nieuws/2026/07/rijbewijs-en-autobezit-stijgt

Dangermond K. en Broeren L. (2025). *De First Responder-taak in Veiligheidsregio Haaglanden. Een onderzoek naar de aanleiding, werkwijze, impact en leerpunten*. Nederlands Instituut Publieke Veiligheid. Geraadpleegd op 20 juli 2026, van https://nipv.nl/wp-content/uploads/2026/06/20251126-NIPV-De-First-Responder-taak-in-Veiligheidsregio-Haaglanden.pdf

Gitlab, Ministerie van Justitie en Veiligheid. (z.d.). *DATAPRO112, voor het uitwisselen van data en code*. Geraadpleegd op 1 mei 2026, van https://git.eminjenv.nl/veiligheidsregio-s-en-nipv/vakgroep-datawetenschappen/datapro112 (Toegankelijk voor NIPV en VR's)

Gitlab, Ministerie van Justitie en Veiligheid. (z.d.). *DATAPRO112: dataladen*. Geraadpleegd op 1 mei 2026, van https://git.eminjenv.nl/veiligheidsregio-s-en-nipv/vakgroep-datawetenschappen/datapro112/dataladen

Gitlab, Ministerie van Justitie en Veiligheid. (z.d.). *DATAPRO112: vergelijking regio's*. Geraadpleegd op 1 mei 2026, van https://git.eminjenv.nl/veiligheidsregio-s-en-nipv/vakgroep-datawetenschappen/datapro112/vergelijking_regios

Gitlab, Ministerie van Justitie en Veiligheid. (z.d.). *DATAPRO112: trends incidenten*. Geraadpleegd op 1 mei 2026, van https://git.eminjenv.nl/veiligheidsregio-s-en-nipv/vakgroep-datawetenschappen/datapro112/02_trends_incidenten

Gitlab, Ministerie van Justitie en Veiligheid. (z.d.). *DATAPRO112: procesanalyse*. Geraadpleegd op 1 mei 2026, van https://git.eminjenv.nl/veiligheidsregio-s-en-nipv/vakgroep-datawetenschappen/datapro112/03_procesanalyse

Gitlab, Ministerie van Justitie en Veiligheid. (z.d.). *DATAPRO112: inzet en opschaling*. Geraadpleegd op 1 mei 2026, van https://git.eminjenv.nl/veiligheidsregio-s-en-nipv/vakgroep-datawetenschappen/datapro112/05_inzet_en_opschaling

Hilt, D. E., & Seegrist, D. W. (1977). *Ridge, a computer program for calculating ridge regression estimates* (Research Note 236). Department of Agriculture, Forest Service, Northeastern Forest Experiment Station.

KNMI. (2020). *Juni 2020*. Geraadpleegd op 25 augustus 2026, van https://www.knmi.nl/nederland-nu/klimatologie/maand-en-seizoensoverzichten/2020/juni

KNMI. (2022). *Drielingstorm Dudley, Eunice en Franklin*. Geraadpleegd op 3 augustus 2026, van https://www.knmi.nl/over-het-knmi/nieuws/drielingstorm-dudley-eunice-en-franklin

KNMI. (z.d.). *Historisch verloop neerslagtekort*. Geraadpleegd op 10 augustus 2026, van https://www.knmi.nl/nederland-nu/klimatologie/geografische-overzichten/historisch-neerslagtekort

Landelijke Meldkamer Samenwerking. (z.d.). *Overzicht Landelijke Meldingsclassificaties, versie 12.0*. Geraadpleegd op 15 juni 2026, van https://www.meldkamersamenwerking.nl/voor-partners

NIPV. (oktober 2022). *Toekomstverkenning Brandweer 2022-2030*. Geraadpleegd op 5 oktober 2026, van 20221012-NIPV-Toekomstverkenning-Brandweer-2022-2030-Interactieve-samenvatting-samenlevingen-en-themas.pdf

NIPV. (z.d.). *Kerncijfers Brandweer: Kerncijfers veiligheidsregio's, cijfers en statistiek rondom brandweer en brandweerzorg*. Geraadpleegd op 3 maart 2026, van https://kerncijfers.nipv.nl

NIPV. (z.d.). *Kerncijfers Incidenten: Kerncijfers veiligheidsregio's*. Geraadpleegd op 3 maart 2026, van https://kerncijfers.nipv.nl/mosaic/kerncijfers-veiligheidsregio-s/kerncijfers-incidenten

NIPV. (z.d.). *Kerncijfers Materieel: Kerncijfers veiligheidsregio's*. Geraadpleegd op 10 juni 2026, van https://kerncijfers.nipv.nl/mosaic/kerncijfers-veiligheidsregio-s/kerncijfers-materieel

NIPV. (z.d.). *Kerncijfers Natuurbranden: Kerncijfers veiligheidsregio's*. Geraadpleegd op 30 juli 2026, van https://kerncijfers.nipv.nl/mosaic/kerncijfers-veiligheidsregio-s/kerncijfers-natuurbranden

Oosterveen, V., Weda, H., De Witte, L., & Matser, A. (2026). *Factors associated with residential fires: Insights from Dutch national incident data*. *Fire Safety Journal, 165*, Article 104942. https://doi.org/10.1016/j.firesaf.2026.104942

Overheid Wettenbank. (2009). *Regeling burgerservicenummer*. Geraadpleegd op 3 augustus 2026, van https://wetten.overheid.nl/BWBR0022835/2009-11-13/1#voetnoot20

Scikit Learn. (2026). *Logistic Regression*. Geraadpleegd op 26 juni 2026, van https://scikit-learn.org/stable/modules/generated/sklearn.linear_model.LogisticRegression.html

Spacy. (2026). *Taalmodel: nl_core_news_sm*. Geraadpleegd op 1 mei 2026, van https://huggingface.co/spacy/nl_core_news_sm

Stichting Salvage. (2026). *Alle feiten en cijfers op een rij*. Geraadpleegd op 5 oktober 2026, van https://stichtingsalvage.nl/media-en-nieuws/?sc=publicaties

Wikipedia (2026). *tf–idf*. Geraadpleegd op 10 augustus 2026, van https://en.wikipedia.org/wiki/Tf%E2%80%93idf

Wikipedia (2026). *Singular value decomposition*. Geraadpleegd op 10 augustus 2026, van https://en.wikipedia.org/wiki/Singular_value_decomposition

Bijlage 1 – Interview

Tabel B1.1. Opzet van het semigestructureerde interview

Deel 1: Van melding naar inzet	
1	Hoe wordt bepaald welke eenheden uitrukken na een incidentmelding?
2	Wanneer bij het bepalen van de eenheden gebruik wordt gemaakt van de kazerne volgorde tabel (KVT): Hoe ziet de KVT eruit? Wanneer wordt ervan afgeweken? Hoe vaak verandert de KVT? Wie maakt de KVT?
3	Wordt vastgelegd welke eenheden zijn uitgerukt? En wie (welke functie) legt dit vast?
4	Wordt vastgelegd welke eenheden daadwerkelijk zijn inzet? Wat wordt er verstaan onder inzet? Hoe betrouwbaar zijn deze data? Verschilt het vastleggen van daadwerkelijke inzet per functie? (bijvoorbeeld. OvD / AGS / vrijwillig)
Deel 2: Tijdens incident	
5	Worden er tijdens inzet gegevens vastgelegd? En hoe gebeurt dit? Worden er gegevens gelogd? Worden er door een informatiemanager gegevens opgeslagen? Hoe wordt er omgegaan met het kladblok in GMS en wat wordt hierin vastgelegd?
6	Worden branden geclassificeerd naar grootte?
7	Wat wordt verstaan onder opschaling?
Deel 3: Na het incident	
8	Worden er na het incident nog gegevens vastgelegd? (Denk aan verificatie incident en aanvullende gegevens over de incidentbestrijding)
9	Worden incidenten gecategoriseerd? Komt deze categorisering overeen met GMS? Welke categorieën worden gehanteerd? Zijn er specifieke type incidenten waarin de VR geïnteresseerd is? En worden hierover extra gegevens bijgehouden? Wordt in een aanvullend system vastgelegd als een meldingsclassificatie in GMS gewijzigd wordt?
Deel 4: Algemene vragen	
10	Worden er rapportages gemaakt over de incidenten en de inzet? Voor wie zijn deze rapportages bedoeld? (b.v., posten/bestuur/management) Met welke tool en in welke vorm komen rapportages beschikbaar? Welke gegevens worden gebruikt voor deze rapportages? Wat is de betrouwbaarheid/nauwkeurigheid van de informatie in de rapportage?
11	Naast de eerder besproken vragen, zijn er verdere gegevens die wordt vastgelegd over incidentafhandeling?
12	Zijn er zaken voor de VR waarvan verwacht kan worden dat deze afwijken van procespatronen en dataverzameling ten opzichte van andere VR's?