



Koninklijk Nederlands
Meteorologisch Instituut
Ministerie van Infrastructuur en Waterstaat

Bepaling van de statistiek van zware neerslag voor het Nederlandse wegennet

handleiding en technische achtergrond van versie 2.1

C.F. de Valk

De Bilt, 2021 | Technisch rapport; TR-393

Inhoudsopgave

Inhoudsopgave	2
1 Doel	3
2 Modelbeschrijving	5
2.1 Uitgangspunten	5
2.2 Foutenanalyse	8
2.2.1 Ontbinding van fouten	8
2.2.2 Steekproeffout	9
2.2.3 Systematische fout	10
3 Berekening van de neerslagstatistiek	14
3.1 Handleiding	14
3.1.1 Basis	14
3.1.2 Toepassing van klimaatscenario's	16
3.1.3 Schatting van de steekproeffout	17
3.2 Rekenvoorbeelden	19
3.3 Code	25
Literatuur	35
Bijlage: Technische achtergrond	36

1 Doel

Voor het ontwerp en beheer van het wegennet is informatie nodig over de statistiek van zware neerslag op een gegeven deel van het wegennet en/of verzameling van kunstwerken, zoals tunnels. Dit wegennetwerk en/of verzameling van kunstwerken kan worden weergegeven als een verzameling S van punten in Nederland. Het is met name van belang antwoorden te vinden op vragen zoals

hoe vaak valt er ergens op S een neerslaghoeveelheid van meer dan (zeg) 25 mm binnen (zeg) 10 minuten?

De frequentie van deze gebeurtenis is natuurlijk groter dan de frequentie waarmee meer dan 25 mm binnen 10 minuten valt op een enkel punt (bijvoorbeeld, een regenmeter). De vraag is, hoeveel groter?

Deze handleiding beschrijft hoe voor een gegeven neerslagduur en voor een gegeven deel van het wegennet en/of verzameling van kunstwerken bepaald kan worden hoeveel vaker een gegeven neerslaghoeveelheid wordt overschreden dan op een enkel punt. We beschouwen neerslagduren van 10 minuten tot 12 uur.

Voor dit doel is een eenvoudig model ontwikkeld dat het effect van de omvang en de ruimtelijke vorm van het beschouwde wegennet en/of verzameling van kunstwerken in rekening brengt. Het model is gebaseerd op een vereenvoudigde weergave van de ruimtelijke samenhang van zware neerslag.

In de toepassing van het model kunnen ook de KNMI'14 scenario's voor toekomstige klimaatverandering worden meegenomen door middel van de keuze van (a) een jaar/scenario voor de neerslagstatistiek voor een enkel punt, en (b) een jaar/scenario voor de te bepalen statistiek voor het gekozen deel van het wegennet. Dit kan momenteel alleen nog voor korte neerslagduren t/m 2 uur.

Het model is beschreven in hoofdstuk 2, inclusief een beschouwing van de onzekerheden in de uitkomsten. Hoofdstuk 3 bevat de handleiding voor de berekening van de statistiek van zware

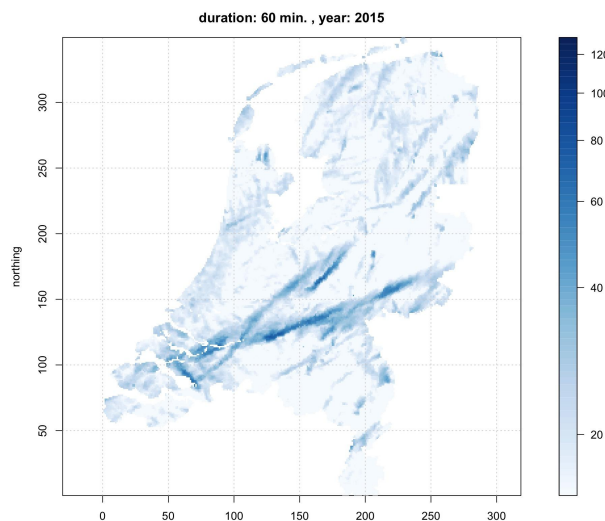
neerslag voor een gegeven wegennet en/of verzameling van kunstwerken. Dit wordt geïllustreerd met een rekenvoorbeeld; dit voorbeeld kan worden gebruikt voor het testen van de berekening. Meer over de wetenschappelijke achtergrond van het model is te vinden in de Bijlage, die is geschreven samen met Aart Overeem.

Dit rapport is tot mede tot stand gekomen dankzij de sturing en de inhoudelijke bijdragen van Paul Fortuin, Ruthger Smit en Ivonne van Pelt van Rijkswaterstaat, en Aart Overeem en Irene Garcia Martí van KNMI.

2 Modelbeschrijving

2.1 Uitgangspunten

De ruimtelijke samenhang van zware neerslag wordt in vereenvoudigde vorm weergegeven door middel van de “voetafdruk” van zware neerslag over de levensduur van de bui. Daarbinnen verplaatst de bui zich onder invloed van de wind. Een indruk van de vormen die zo'n voetafdruk kan hebben is te zien in Figuur 1; deze toont voor de 1-uurs neerslag gemiddeld over pixels van $900\text{ m} \times 900\text{ m}$ de maximale neerslag over een jaar, afgeleid van radargegevens.



Figuur 1: Maximum van de 60-minuten neerslag in mm over 2015, afgeleid uit radargegevens.

In het model wordt de voetafdruk van een “gemiddelde bui” vereenvoudigd tot een rechthoekige strook van vaste lengte en breedte. De breedte en lengte, in pixels, zijn afhankelijk van de beschouwde neerslagduur τ in minuten als volgt:

$$\text{breedte} = 1.06 \tau^{0.255}, \quad \text{lengte} = 10.2 \tau^{0.128}. \quad (\text{i})$$

De vier parameters in bovenstaande vergelijkingen (1.06 etc.) zijn geschat uit de radargegevens.


De neerslag is uniform over de voetafdruk verondersteld, en nul daarbuiten. De oriëntatie van de voetafdruk is willekeurig, met een uniforme verdeling over de richtingen. Het middelpunt van de voetafdruk is willekeurig en uniform verdeeld over een gebied dat Nederland omvat.

Stel, S is het deel van het wegennet en/of verzameling van kunstwerken waarvoor de neerslagstatistiek bepaald moet worden. Dan wordt S eerst vereenvoudigd tot de verzameling radar-pixels die S bedekken. Het aantal radar-pixels in S noemen we $|S|$.

Voor iedere voetafdruk van een bui kunnen we nu de volgende grootheden bepalen:

1. Het aantal pixels n_s in S dat bedekt is door de voetafdruk
2. Een indicator i_s die gelijk is aan 1 als $n_s > 0$, en anders gelijk is aan 0.

Een voorbeeld is gegeven in Figuur 2, waarin S een blok van 10×10 pixels is. In dit geval is $i_s = 1$ en $n_s = 15$. De gemiddelden En_s en Ei_s van n_s en i_s worden berekend door simulatie van de voetafdrukken van buien met willekeurige middelpunten en oriëntaties. Er worden minimaal 50,000 voetafdrukken gesimuleerd die minstens 1 pixel van S bedekken.



Figuur 2: Een blok van 10×10 pixels met een gesimuleerde voetafdruk en hun overlap.

Fixeer de neerslagduur τ . Stel, T_a is de terugkeertijd (d.w.z., 1 gedeeld door de frequentie van overschrijding) van een neerslaghoeveelheid a binnen de duur τ op een enkele pixel. En stel, $T_{S,a}$ is de terugkeertijd van de neerslaghoeveelheid a binnen de duur τ ergens op een pixel in S . Merk

op dat $\xi_S = T_{S,a}/T_a$ onafhankelijk is van a in het model. Bovendien moet gelden dat

$En_S/T_{S,a} = |S| Ei_S/T_a$, en dus:

$$\xi_S = \frac{T_{S,a}}{T_a} = \frac{En_S}{|S| Ei_S}. \quad (ii)$$

Dit getal wordt voor iedere neerslagduur berekend en uitgevoerd.

Merk ook op dat de waarde van ξ_S is bepaald met de ruimtelijke resolutie van een radar-pixel.

Eigenlijk zouden we deze verhouding willen bepalen voor een hogere resolutie die relevant is voor de hemelwaterafvoer van een wegdek; dit zou een kleinere verhouding geven (verder weg van 1). Daarom geeft de waarde van ξ_S geschat op basis van radargegevens een overschatting (andere factoren buiten beschouwing gelaten).

We stellen nu T_a gelijk aan de terugkeertijd van a voor een regenmeter, bepaald uit schattingen van de Generalized Extreme Value (GEV) verdeling van jaarmaxima afgeleid uit de analyseresultaten gepresenteerd in deel 1 van het STOWA (2019) rapport (zie Bijlage). Met behulp van de aldus bepaalde waarde van T_a en de eerder berekende ξ_S kunnen we nu direct $T_{S,a}$, de terugkeertijd van de neerslaghoeveelheid a ergens op S , bepalen als (zie (ii)):

$$T_{S,a} = \xi_S T_a.$$

De waarde van T_a op de hoge ruimtelijke resolutie van een regenmeter is naar verwachting lager dan de terugkeertijd van de neerslag a op de lagere ruimtelijke resolutie die relevant is voor de hemelwaterafvoer van een wegdek. Echter, deze onderschatting valt deels weg tegen de overschatting van $\xi_S = T_{S,a}/T_a$ (zie boven). Grootte en teken van de netto fout zijn niet bekend.

Een waarschuwing: de GEV schattingen die gebruikt worden om de terugkeertijd T_a te bepalen wijken enigszins af van de in deel 1 van STOWA (2019) aanbevolen waarden afgeleid op basis

van de GLO verdeling, vooral voor grote terugkeertijden! De motivatie voor deze afwijking is uiteengezet in de Bijlage.

Behalve voor de berekening van terugkeertijden van een gegeven neerslaghoeveelheid kan het model ook gebruikt worden om de neerslaghoeveelheid te bepalen die met een gegeven terugkeertijd ergens op Svalb. Het model berekent voor een gegeven terugkeertijd T de verhouding b/a , met a en b de neerslaghoeveelheden waarvoor $T_a = T_{S,b} = T$. Deze kunnen we interpreteren als de gemiddelde verhouding van de zwaarste neerslag die ergens op S valt ten opzichte van de neerslag op een punt, beide met dezelfde terugkeertijd (bijvoorbeeld: de eens per 10 jaar ergens op S overschreden neerslag over 10 min. gedeeld door de eens per 10 jaar op een punt overschreden neerslag over 10 min.).

De aanpassingen van de neerslagstatistiek voor een aantal toekomstscenario's van het klimaat van extreme neerslag in Nederland worden berekend voor neerslagduren tot en met 2 uur op basis van Tabel 5 in hoofdstuk 3 van deelrapport 2 in STOWA (2019). We nemen daarbij aan dat de ruimtelijke afhankelijkheid van extreme neerslag niet zal veranderen. De literatuur bevat aanwijzingen dat de ruimtelijke schaal van zware buien kan toenemen als gevolg van toekomstige opwarming (Lochbihler et al, 2017). Dit zou de verhouding $T_{S,a}/T_a$ verhogen, met als effect dat $T_{S,a}$ verhoudingsgewijs minder zal afnemen dan T_a . Door dit effect te negeren blijven we dus aan de veilige kant.

Een gedetailleerde beschrijving van de technische achtergrond van het model, een verantwoording van de aannamen en een verificatie op basis van de radargegevens is te vinden in de Bijlage.

2.2 Foutenanalyse

Deze sectie kan bij een eerste lezing worden overgeslagen. Echter, aangeraden wordt om het model niet eerder te gebruiken dan na kennis te nemen van de inhoud, omdat een goed begrip van de onzekerheden in de modelberekeningen belangrijk is voor een juiste toepassing.

2.2.1 Ontbinding van fouten

De fout in een door het model berekende grootte bestaat uit

- a. een steekproeffout (toevalsfout) die het gevolg is van de kalibratie van het model op een beperkt aantal waarnemingen, die ook nog eens onderling afhankelijk kunnen zijn;
- b. een systematische fout (bias): deze verdwijnt niet als de modelkalibratie herhaald wordt op nieuwe (vergelijkbare) datasets en de uitkomsten van al deze modellen gemiddeld worden.

In de praktijk spelen beide typen fouten altijd een rol. De orde van grootte van de steekproeffout kan in de meeste situaties geschat worden uit de data. Het is lastiger om de systematische fout te bepalen. Het is in het algemeen wenselijk dat de systematische fout aanzienlijk kleiner is dan de steekproeffout: in dat geval geeft een schatting van de steekproeffout meteen ook een goede indruk van de totale fout.

2.2.2 Steekproeffout

De steekproeffout van het model is geschat met een block bootstrap methode:

1. trek 11 willekeurige jaren met teruglegging (!) uit de jaren 2008-2018,
2. schat uit de data van deze jaren (waarin dus gegevens van bepaalde jaren ontbreken en gegevens van andere jaren meerdere malen voorkomen) de vier parameters die de lengte en breedte van de bui vastleggen voor iedere neerslagduur (de numerieke constanten in vergelijking (i)), en
3. herhaal het bovenstaande 50 keer.

We hebben nu (inclusief de oorspronkelijke data) een ensemble van 51 realisaties van de vier parameters. Met dit ensemble kunnen we nu betrouwbaarheidsintervallen schatten van deze parameters, maar eveneens van iedere andere door het model voorspelde grootte. Met name kunnen we voor een gegeven wegennet S een ensemble van waarden van de verhouding $\xi_S = T_{S,a}/T_a$ bepalen. De spreiding daarin wordt vervolgens uitgedrukt in de standaardafwijking van de logaritme van ξ_S (de steekproeffout in deze logaritme kan bij benadering als normaal verdeeld worden beschouwd).

De ruimtelijke samenhang van zware neerslag is echter niet de enige bron van onzekerheid: ook de relatie tussen neerslaghoeveelheid a en terugkeertijd T_a op een punt (regenmeter), bepaald uit de gegevens van weerstations verspreid over het land (STOWA, 2019), heeft een steekproeffout.

Bij een gegeven terugkeertijd is er onzekerheid in de neerslaghoeveelheid, en bij een gegeven neerslaghoeveelheid is er onzekerheid in de terugkeertijd. Over de systematische fout in deze schattingen kunnen we niet zoveel zeggen, maar de steekproeffout wordt geschat met een methode die “parametric bootstrap” genoemd wordt; dit komt neer op simulatie van jaarmaxima van de neerslag op een punt en van de schatting van de statistiek daaruit. In deze simulatie wordt ook meteen de steekproeffout in de geschatte verhouding $\xi_{S,a} = T_{S,a} / T_a$ meegenomen; de logaritme van $\xi_{S,a}$ wordt beschouwd als normaal verdeeld, onafhankelijk van de statistiek voor een punt, en met standaardafwijking geschat uit de bootstrap (zie boven).

Het model geeft een schatting van de verhouding $\xi_{S,a} = T_{S,a} / T_a$ met een bovengrens en een ondergrens. De bovengrens is de bovengrens van een betrouwbaarheidsinterval voor $T_{S,a}$ bij gegeven neerslaghoeveelheid a , waarin alle bronnen van steekproeffout zijn meegenomen, gedeeld door de nominale schatting van T_a . We kunnen deze bovengrens dus meteen vermenigvuldigen met T_a om de bovengrens van het betrouwbaarheidsinterval voor $T_{S,a}$ te vinden. Het is dus niet de bovengrens van een betrouwbaarheidsinterval voor de verhouding $\xi_{S,a} = T_{S,a} / T_a$ zoals geschat uit de radardata! De reden om alle bronnen van steekproeffout mee te nemen in de bovengrens is dat het lastig is om later nog de effecten van verschillende foutenbronnen te combineren. Immers, het gaat uiteindelijk om het gecombineerde effect van alle bronnen samen.

De definitie van de ondergrens is analoog.

Voor de onzekerheid in de neerslaghoeveelheid bij een gegeven terugkeertijd is een analoge aanpak gevolgd. Het model berekent voor een gegeven terugkeertijd T de verhouding b/a , met a en b de neerslaghoeveelheden waarvoor $T_a = T_{S,b} = T$. De gegeven bovengrens is een bovengrens voor b bij gegeven T (gebaseerd op alle bronnen van steekproefonzekerheid) gedeeld door de nominale waarde van a . Voor neerslaghoeveelheid is de steekproeffout in hoge mate bepaald door de steekproeffout in de statistiek voor een punt.


Voorbeelden van berekeningen met schattingen van de steekproeffout worden beschreven in Sectie 3.1.3.

2.2.3 Systematische fout

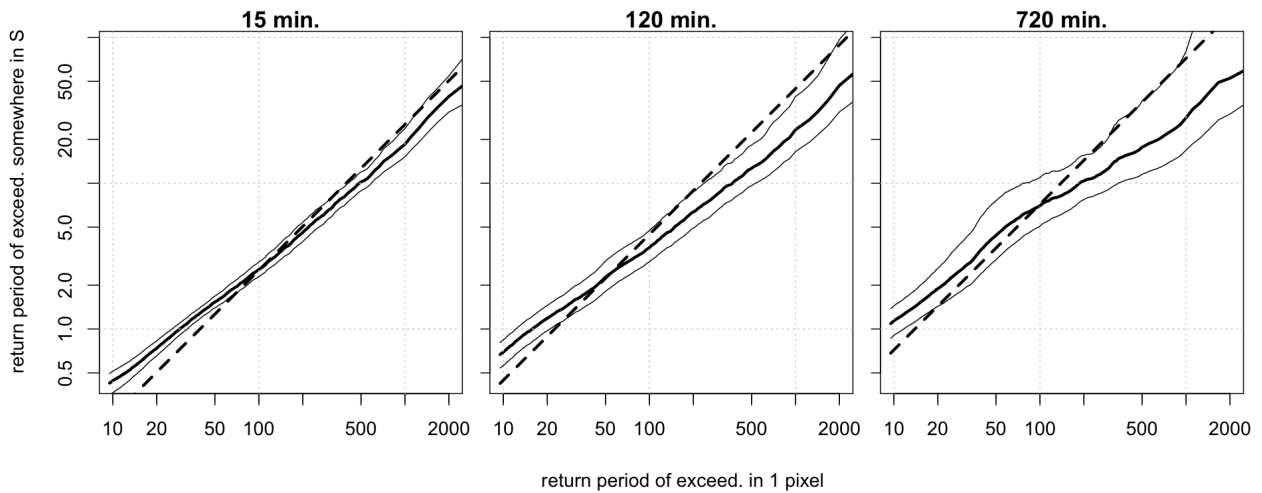
De systematische fout in de schattingen van de statistiek van zware neerslag op een enkel punt (uit STOWA, 2019) is lastig te bepalen. Deze heeft wel een rol gespeeld in de keuze van de methode: voor jaarmaxima is de GEV verdeling gebruikt in plaats van de GLO verdeling gepresenteerd in STOWA (2019) omdat de systematische fout in de laatste te groot blijkt, met name voor grote terugkeertijden.

De systematische fout in de verhouding $\xi_S = T_{S,a}/T_a$ (die het effect van de ruimtelijke samenhang weergeeft op de terugkeertijd $T_{S,a}$ van de zwaarste neerslag op een wegennet S) kan tot op zekere hoogte worden geverifieerd met de radargegevens. Het is ideaal om daarvoor radargegevens te gebruiken die niet zijn gebruikt voor kalibratie van het model. Dit is echter niet haalbaar, omdat we slechts 11 jaar radargegevens beschikbaar hebben. Wat we wel kunnen verifiëren is of het model in staat is te generaliseren van de bijzondere keuzen van S waarvoor het gekalibreerd is naar willekeurige delen van het hoofdwegennet.

Voor een gekozen deel van het hoofdwegennet bedekt door de radarpixels in S worden voor een gegeven neerslaghoeveelheid a zowel T_a als $T_{S,a}$ direct geschat uit de radargegevens, en de relatie tussen beide (met a variërend over het waardebereik van de radargegevens) is geplott op een dubbel-logaritmische schaal in Figuur 4 (doorgetrokken lijnen). Tevens wordt de berekende relatie tussen T_a als $T_{S,a}$ geplott (streepjeslijnen); de laatste heeft een lijn met helling gelijk aan 1.



Figuur 3: Pixels die een gekozen deel van het hoofdwegennet bedekken.



Figuur 4: Terugkeertijd $T_{S,a}$ voor de pixels in Figuur 3 versus terugkeertijd T_a voor een enkele pixel volgens het model (gestreept dik) en direct geschat uit de radargegevens (doorgetrokken dik), met de geschatte 95% betrouwbaarheidsintervallen van de laatste (dun), voor drie verschillende neerslagduren.

terugkeertijd T_a (jaar)	neerslagduur (min)		
	15	120	720
10	-0.56/0.14	-0.44/0.14	-0.46/0.16
20	-0.34/0.21	-0.20/0.21	-0.23/0.22
50	-0.19/0.28	-0.02/0.27	-0.20/0.29
100	-0.01/0.36	+0.21/0.35	+0.03/0.36
250	+0.11/0.50	+0.40/0.47	+0.46/0.48

Tabel 1: Verhouding van $\log T_{S,a} - \log \hat{T}_{S,a}$ (teller) tot $\sigma(\log T_{S,a})$ (noemer), met $T_{S,a}$ de terugkeertijd voor het wegennet in Figuur 3 berekend met het model, $\hat{T}_{S,a}$ de terugkeertijd geschat uit de radargegevens, en $\sigma(\log T_{S,a})$ de standaardafwijking van $\log T_{S,a}$ (d.w.z. de relatieve steekproeffout in de terugkeertijd berekend met het model), als functie van de neerslagduur (min) en de terugkeertijd voor een enkel punt $T_{0,a}$.

In Tabel 1 is de afwijking tussen de berekende en direct uit de data geschatte terugkeertijden (als indicator voor de systematische fout) uitgedrukt als fractie van de steekproeffout van de

modelberekening¹ zoals bepaald in Sectie 2.2.2 (we beschouwen hier de relatieve fouten, maar dat maakt voor het resultaat weinig verschil). Deze tabel wijst op een systematische fout kleiner dan de standaardafwijking van de modelberekening voor terugkeertijden voor een enkel punt van 50 jaar en meer. Voor lagere terugkeertijden kan de systematische fout groter zijn dan de (zeer lage) standaardafwijking, maar worden terugkeertijden voor het wegennetwerk door het model onderschat (dus frequenties worden overschat). Het model blijft hier dus iets aan de veilige kant; de afwijking in terugkeertijd is voor het beschouwde wegennet kleiner dan ruwweg een factor 2 (zie Figuur 4).

De werkelijke systematische fout kan ook veel kleiner zijn dan Tabel 1 suggereert: de door het model voorspelde terugkeertijden (gestreepte lijnen in Figuur 4) liggen dicht bij de betrouwbaarheidsintervallen uit de directe schattingen uit de radargegevens (de doorgetrokken lijnen). Bovendien zijn deze (met de bootstrap geschatte) intervallen eerder te smal dan te breed. Het is daarom op grond van de huidige gegevens niet hard te maken dat het model een systematische fout heeft; we hebben wel een indicatie. Bovenstaande resultaten zijn representatief voor het deel van het hoofdwegennet binnen een willekeurig gebied van ongeveer $30 \times 30 \text{ km}^2$. Voor kleinere (grotere) delen van het wegennet zal de systematische fout uiteraard kleiner (groter) zijn.

¹ Dit is inclusief de bijdrage aan de steekproeffout van de schatting van de neerslagstatistiek voor een punt; zie Sectie 2.2.2.

3 Berekening van de neerslagstatistiek

3.1 Handleiding

3.1.1 Basis

De neerslagstatistiek voor een gegeven deel van het wegennet en/of verzameling van kunstwerken wordt bepaald uit de positiegegevens van de wegen en/of kunstwerken.

De laatste dienen te worden opgeslagen in een csv (comma-separated value) bestand met de naam

```
wegennet4neerslagstat.csv
```

De positiegegevens van de wegen/kunstwerken dienen te worden opgegeven in een lokaal coördinatenstelsel in de eenheid meter, bijvoorbeeld rd (rijksdriehoeken) coördinaten. Het format is:

- eerst een kopregel met een korte beschrijving in een enkele karakter-string,
- daaronder op elke regel het oostwaartse coördinaat en het noordwaartse coördinaat, gescheiden door een komma.

Bijvoorbeeld:

```
HoofdwegenProvUtrecht  
oost-coordinaat, noord-coordinaat  
oost-coordinaat, noord-coordinaat  
oost-coordinaat, noord-coordinaat  
.....
```

Aanbevolen wordt om voor de positie van een weg de posities van de hectometerpalen te gebruiken, of een vergelijkbaar dichte set van posities. Het is geen enkel probleem als een positie meerdere malen in het bestand voorkomt.

De neerslagstatistiek wordt vervolgens bepaald door het draaien van een script binnen het rekenprogramma R. In de Windows 10 omgeving kunt u als volgt controleren of R is geïnstalleerd: Klik het icoon



om het Windows start menu op te roepen, en kijk onder de letter R of R daar in voorkomt.

Als R niet geïnstalleerd is kan uw systeembeheerder wellicht assisteren met de installatie.

Als R wel geïnstalleerd is:

Start R op via het Windows start menu; mogelijk moet u daarvoor twee maal een icoon aanklikken. Dan verschijnt een venster waarin u commando's kunt tikken.

1. Bovenaan het R-venster staat een menu. Kies `File` en daarna `Change dir ...` om naar de map te navigeren waarin het script `RainRoadStat_2p1.R` en het invoerbestand `wegennet4neerslagstat.csv` staan. U kunt dit verifiëren door `dir()` in het R venster te tikken.
2. Kies `File` en daarna `Source R code ...`. In het pop-up venster kiest u vervolgens het bestand `RainRoadStat_2p1.R`.

Er rolt voortgangsinformatie over het venster; als dit stopt is de statistiek berekend.

3. In bovengenoemde map staan nu de uitvoerbestanden. De namen van de uitvoerbestanden bevatten de kopregel van het invoerbestand, ter identificatie. In het eerder gegeven voorbeeld zijn deze:

```
TerugkeertijdFactoren_HoofdwegenProvUtrecht.csv  
NeerslagFactoren_HoofdwegenProvUtrecht.csv.
```

Het eerste bestand bevat de factor waarmee de **terugkeertijd** van een neerslaghoeveelheid **op een enkel punt** dient te worden vermenigvuldigd om de **terugkeertijd voor de beschouwde wegen/kunstwerken** te bepalen.

Het tweede bestand bevat voor iedere neerslagduur en terugkeertijd de factor waarmee de bijbehorende neerslaghoeveelheid **voor een enkel punt** moet worden vermenigvuldigd om de neerslaghoeveelheid **voor de beschouwde wegen/kunstwerken** te krijgen. De tabel met de neerslaghoeveelheden voor een enkel punt en voor het huidige klimaat (referentiejaar 2014) staat hieronder.

	0.5	1	2	5	10	20	25	50	100	200	250
10	8.1	10.2	12.4	15.6	18.1	20.9	21.8	24.8	27.9	31.3	32.4
15	8.8	11.2	13.9	17.8	21	24.4	25.6	29.4	33.6	38.1	39.6
30	10.4	13.5	16.9	22.0	26.4	31.2	32.9	38.4	44.5	51.3	53.6
60	12.5	16.2	20.4	26.8	32.3	38.5	40.7	47.9	56.1	65.3	68.5
120	15.3	19.5	24.4	31.8	38.3	45.7	48.3	57.0	66.9	78.1	82.0
240	18.6	23.4	28.8	37.2	44.5	52.8	55.8	65.6	76.8	89.4	93.9
480	22.4	27.7	33.8	42.9	50.9	59.9	63.1	73.6	85.5	99.0	103.7
720	24.8	30.5	36.9	46.4	54.7	63.9	67.1	77.9	89.9	103.4	108.1

Tabel 2: Neerslaghoeveelheid (in mm) **voor een enkel punt** bij gegeven terugkeertijd (in jaren; eerste rij) en gegeven neerslagduur (in minuten; eerste kolom), voor het huidige klimaat (referentiejaar 2014).

- U kunt deze uitvoerbestanden vervolgens importeren in Excel (zie onder *Gegevens* in het menu; zorg dat in het pop-up venster *Gegevenstypedetectie op Geen gegevenstypen detecteren staat!*).

3.1.2 Toepassing van klimaatscenario's

Voor korte duren tot en met 2 uur zijn toekomstscenario van de neerslagstatistiek gegeven als factoren waarmee de neerslaghoeveelheid voor een gegeven terugkeertijd vermenigvuldigd dient te worden. Tabel 5 in hoofdstuk 3 van deelrapport 2 in STOWA (2019) geeft deze factoren:

jaar/scenari o	2014	2030laag	2030hoog	2050laag	2050hoog	2085laag	2085hoog
factor	1.000	1.039	1.077	1.039	1.213	1.064	1.411

Tabel 3: Toename van de korte-duur neerslag in de scenario's volgens STOWA (2019): factoren t.o.v. de neerslag in het klimaat van referentiejaar 2014 voor duren van 10 min tot 2 uur.

Op basis van deze factoren kunnen berekeningen van zowel neerslaghoeveelheden (bij gegeven terugkeertijd) als terugkeertijden (bij een gegeven neerslaghoeveelheid) worden aangepast aan een gekozen combinatie van jaar en scenario.

Het model berekent alleen verhoudingen (van terugkeertijden op het beschouwde wegennet en op een enkel punt, of van neerslaghoeveelheden op het beschouwde wegennet en op een enkel punt bij een gegeven terugkeertijd). In zo'n verhouding kan ook de conversie van het klimaat in een gekozen jaar/scenario naar een ander jaar/scenario in rekening worden gebracht. Dit kan door het invoeren van

1. een jaar/scenario voor de neerslagstatistiek voor een punt, en daarna
 2. een jaar/scenario voor de neerslagstatistiek voor het beschouwde wegennet,
- beide aangeduid als in de koprij van Tabel 3.

Dit gebeurt door in de kopregel van het invoerbestand `wegennet4neerslagstat.csv` deze twee jaar/scenario combinaties toe te voegen na de omschrijving van het wegennet, gescheiden door een komma en gescheiden van de omschrijving door een komma. Bijvoorbeeld:

```
HoofdwegenProvUtrecht, 2085laag, 2014
    oost-coordinaat, noord-coordinaat
    oost-coordinaat, noord-coordinaat
    .....
```

In dit voorbeeld is `2085laag` dus het jaar/scenario voor de neerslagstatistiek voor een punt, en `2014` is het jaar/scenario voor de neerslagstatistiek voor het beschouwde wegennet `HoofdwegenProvUtrecht`. In dit geval bevat de tabel in het uitvoerbestand `TerugkeertijdFactoren_HoofdwegenProvUtrecht.csv` bij een terugkeertijd van zeg 10 jaar en een neerslagduur van 30 minuten: { 1/10 } *maal* { de terugkeertijd in 2014 van een overschrijding ergens op `HoofdwegenProvUtrecht` binnen 30 minuten } *van* { de 10-jaars neerslag over 30 minuten op een enkel punt volgens het lage scenario voor 2085 }.

3.1.3 Schatting van de steekproeffout

Optioneel kan ook de onzekerheid in de uitvoer van het model worden geschat; dit betreft uitsluitend de steekproeffout ten gevolge van de kalibratie van het model op een beperkt aantal waarnemingen (dus NIET de systematische fout; zie 2.2.3 voor een afschatting daarvan). Deze onzekerheid wordt weergegeven door middel van de ondergrens en de bovengrens van een

betrouwbaarheidsinterval: dat is een interval waarin de werkelijke waarde met een gegeven kans p moet liggen wanneer de data-inwinning en schatting herhaald zouden worden (en, zoals gezegd, de systematische fout genegeerd wordt).

Deze ondergrens en bovengrens worden alleen berekend als de kans p in de kopregel van het invoerbestand `wegennet4neerslagstat.csv` staat: na de omschrijving van het beschouwde wegennet of kunstwerk, en gescheiden van de omschrijving (en van evt. jaar/scenario specificaties als in 3.1.2) door komma's. Bijvoorbeeld:

```
HoofdwegenProvUtrecht, 0.95
oost-coordinaat, noord-coordinaat
oost-coordinaat, noord-coordinaat
.....
```

of

```
HoofdwegenProvUtrecht, 2085laag, 2014, 0.95
oost-coordinaat, noord-coordinaat
oost-coordinaat, noord-coordinaat
.....
```

(p is dus 0.95 in bovenstaande voorbeelden). De berekening met onder- en bovengrenzen kost ongeveer zes maal meer rekentijd dan de berekening zonder deze grenzen.

Voor de factoren op de terugkeertijd worden de berekende grenzen opgeslagen in bestanden genaamd (bijvoorbeeld)

```
TerugkeertijdFactorenOndergrens95%_HoofdwegenProvUtrecht.csv
TerugkeertijdFactorenBovengrens95%_HoofdwegenProvUtrecht.csv
```

en voor de factoren op de neerslaghoeveelheid worden de berekende grenzen opgeslagen in bestanden genaamd (bijvoorbeeld)

```
NeerslagFactorenOndergrens95%_HoofdwegenProvUtrecht.csv
NeerslagFactorenBovengrens95%_HoofdwegenProvUtrecht.csv.
```

3.2 Rekenvoorbeelden

Een voorbeeld van een invoerbestand is `wegennet4neerslagstat-voorbeeld2.csv`. De inhoud van dit bestand is:

```
WegennetVoorbeeld2, 0.95
0,0
300, 300
600, 600
900, 900
1200, 1200
1500, 1500
1800, 1800
2100, 2100
2400, 2400
2700, 2700
2800, 2800
```

Deze bevat de positiegegevens van een imaginair wegtraject van ongeveer 4 km lengte, aangeduid als `WegennetVoorbeeld2`. De kopregel geeft ook aan dat de onder- en bovengrens van het 95% betrouwbaarheidsinterval van iedere door het model berekende waarde dienen te worden berekend.

Dupliceer dit bestand en sla het op als invoerbestand met de generieke naam

```
wegennet4neerslagstat.csv
```

(zie Sectie 3.1). Voer vervolgens de in Sectie 3.1 beschreven stappen uit om de neerslagstatistiek op het ingevoerde `wegennet` te berekenen. Als dit goed is gegaan zijn de uitvoerbestanden en hun inhoud als volgt. Kleine afwijkingen in de uitkomsten van verschillende runs komen voor omdat gebruik wordt gemaakt van simulatie van random getallen; voor de onder- en bovengrenzen van betrouwbaarheidsintervallen zijn de afwijkingen wat groter.

a. TerugkeertijdFactoren_WegennetVoorbeeld2_0.95.csv

0	0.5	1	2	5	10	20	25	50	100	200	250
10	0.394	0.394	0.394	0.394	0.394	0.394	0.394	0.394	0.394	0.394	0.394
15	0.415	0.415	0.415	0.415	0.415	0.415	0.415	0.415	0.415	0.415	0.415
30	0.457	0.457	0.457	0.457	0.457	0.457	0.457	0.457	0.457	0.457	0.457
60	0.498	0.498	0.498	0.498	0.498	0.498	0.498	0.498	0.498	0.498	0.498
120	0.534	0.534	0.534	0.534	0.534	0.534	0.534	0.534	0.534	0.534	0.534
240	0.575	0.575	0.575	0.575	0.575	0.575	0.575	0.575	0.575	0.575	0.575
360	0.598	0.598	0.598	0.598	0.598	0.598	0.598	0.598	0.598	0.598	0.598
480	0.612	0.612	0.612	0.612	0.612	0.612	0.612	0.612	0.612	0.612	0.612
720	0.634	0.634	0.634	0.634	0.634	0.634	0.634	0.634	0.634	0.634	0.634

b. TerugkeertijdFactorenOndergrens_WegennetVoorbeeld2_0.95.csv

0	0.5	1	2	5	10	20	25	50	100	200	250
10	0.353	0.35	0.343	0.327	0.305	0.275	0.264	0.228	0.19	0.153	0.142
15	0.374	0.371	0.363	0.346	0.323	0.291	0.279	0.241	0.202	0.165	0.153
30	0.413	0.41	0.401	0.381	0.355	0.32	0.308	0.267	0.225	0.185	0.173
60	0.451	0.447	0.438	0.416	0.387	0.349	0.336	0.292	0.247	0.205	0.192
120	0.484	0.479	0.469	0.446	0.415	0.375	0.36	0.314	0.267	0.222	0.208
240	0.52	0.515	0.504	0.479	0.446	0.403	0.387	0.337	0.287	0.239	0.224
360	0.54	0.535	0.524	0.498	0.464	0.419	0.403	0.351	0.298	0.248	0.232
480	0.553	0.548	0.536	0.51	0.475	0.429	0.412	0.359	0.304	0.253	0.237
720	0.572	0.567	0.555	0.528	0.492	0.444	0.427	0.371	0.314	0.26	0.243

c. TerugkeertijdFactorenBovengrens_WegennetVoorbeeld2_0.95.csv

0	0.5	1	2	5	10	20	25	50	100	200	250
10	0.439	0.443	0.452	0.474	0.508	0.563	0.586	0.68	0.817	1.01	1.09
15	0.461	0.465	0.475	0.499	0.535	0.593	0.618	0.715	0.854	1.05	1.13
30	0.505	0.51	0.521	0.548	0.588	0.652	0.679	0.782	0.927	1.13	1.21
60	0.549	0.554	0.566	0.596	0.64	0.71	0.738	0.849	1	1.21	1.29
120	0.589	0.595	0.608	0.64	0.687	0.761	0.792	0.909	1.07	1.29	1.37
240	0.635	0.641	0.655	0.689	0.74	0.82	0.852	0.979	1.15	1.38	1.47
360	0.661	0.667	0.682	0.717	0.77	0.853	0.887	1.02	1.2	1.44	1.54
480	0.677	0.683	0.698	0.735	0.789	0.873	0.908	1.04	1.23	1.48	1.58
720	0.702	0.708	0.723	0.761	0.817	0.905	0.941	1.08	1.28	1.55	1.65

d. NeerslagFactoren_WegennetVoorbeeld2_0.95.csv

0	0.5	1	2	5	10	20	25	50	100	200	250
10	1.352	1.297	1.26	1.225	1.205	1.19	1.185	1.173	1.164	1.155	1.153
15	1.358	1.303	1.265	1.23	1.211	1.196	1.192	1.181	1.171	1.164	1.161
30	1.341	1.29	1.256	1.225	1.208	1.195	1.191	1.181	1.173	1.166	1.164
60	1.301	1.261	1.233	1.207	1.194	1.183	1.18	1.171	1.165	1.159	1.158
120	1.252	1.224	1.203	1.184	1.173	1.165	1.162	1.156	1.151	1.146	1.145
240	1.204	1.184	1.17	1.155	1.147	1.141	1.139	1.134	1.13	1.127	1.126
360	1.181	1.164	1.152	1.14	1.133	1.127	1.126	1.121	1.118	1.115	1.114
480	1.166	1.151	1.14	1.129	1.123	1.118	1.117	1.113	1.109	1.107	1.106
720	1.147	1.134	1.124	1.115	1.109	1.105	1.103	1.1	1.097	1.094	1.094

e. NeerslagFactorenOndergrens_WegennetVoorbeeld2_0.95.csv

0	0.5	1	2	5	10	20	25	50	100	200	250
10	1.304	1.25	1.207	1.157	1.12	1.084	1.072	1.037	1.003	0.9697	0.9592
15	1.309	1.253	1.21	1.158	1.12	1.083	1.071	1.034	0.9982	0.9632	0.9521
30	1.291	1.239	1.199	1.149	1.111	1.073	1.061	1.023	0.9862	0.9497	0.9381
60	1.253	1.211	1.177	1.132	1.096	1.06	1.048	1.01	0.9731	0.9362	0.9245
120	1.208	1.177	1.15	1.112	1.08	1.045	1.034	0.9982	0.9619	0.9256	0.9139
240	1.164	1.141	1.121	1.089	1.061	1.029	1.019	0.9849	0.9503	0.9153	0.904
360	1.142	1.123	1.105	1.077	1.05	1.021	1.011	0.9781	0.9447	0.9107	0.8997
480	1.13	1.112	1.096	1.069	1.044	1.016	1.006	0.9746	0.942	0.9089	0.8981
720	1.113	1.097	1.082	1.058	1.035	1.008	0.9993	0.9696	0.9386	0.9068	0.8964

f. NeerslagFactorenBovengrens_WegennetVoorbeeld2_0.95.csv

0	0.5	1	2	5	10	20	25	50	100	200	250
10	1.401	1.347	1.314	1.296	1.297	1.306	1.31	1.328	1.35	1.377	1.386
15	1.41	1.355	1.323	1.307	1.31	1.322	1.327	1.348	1.375	1.406	1.417
30	1.393	1.344	1.316	1.306	1.313	1.33	1.337	1.363	1.395	1.432	1.445
60	1.351	1.313	1.292	1.288	1.299	1.32	1.328	1.358	1.394	1.435	1.45
120	1.298	1.272	1.259	1.26	1.274	1.297	1.306	1.339	1.377	1.42	1.435
240	1.246	1.229	1.221	1.226	1.241	1.265	1.274	1.307	1.345	1.388	1.403
360	1.22	1.206	1.2	1.206	1.221	1.245	1.254	1.285	1.323	1.365	1.379
480	1.204	1.192	1.187	1.193	1.208	1.231	1.239	1.27	1.306	1.347	1.362
720	1.183	1.173	1.168	1.174	1.188	1.21	1.218	1.247	1.282	1.321	1.334

Een tweede voorbeeld is het invoerbestand `wegennet4neerslagstat-voorbeeld1.csv`. Dit bevat posities van een groter wegennet. De kopregel bevat: `WegennetVoorbeeld1, 2014, 2085hoog, 0.95`. Dit betekent dat 95%-betrouwbaarheidsintervallen worden berekend, en dat de berekende verhoudingen betrekking hebben op de statistiek voor het wegennet in het hoge scenario voor 2015, ten opzichte van dezelfde statistiek voor een punt in het referentiejaar 2014 (zie 3.1.2).

Om het model toe te passen op deze data moet het eerst weer gedupliceerd worden naar een bestand met de standaardnaam `wegennet4neerslagstat.csv`. Merk op dat alleen berekeningen zijn gedaan voor neerslagduren van 120 minuten en korter (zie 3.1.2).

g. `TerugkeertijdFactoren_WegennetVoorbeeld1_2014_2085hoog_0.95.csv`

0	0.5	1	2	5	10	20	25	50	100	200	250
10	0.00984	0.00838	0.0072	0.00595	0.00519	0.00456	0.00438	0.00388	0.00346	0.0031	0.003
15	0.0115	0.00989	0.00858	0.00721	0.00637	0.00568	0.00549	0.00494	0.00448	0.00408	0.00397
30	0.0145	0.0126	0.0111	0.00952	0.00857	0.00779	0.00756	0.00694	0.00642	0.00597	0.00585
60	0.0173	0.0152	0.0136	0.0118	0.0108	0.00994	0.0097	0.00902	0.00845	0.00797	0.00784
120	0.0196	0.0175	0.0157	0.0139	0.0129	0.012	0.0117	0.011	0.0104	0.00989	0.00975

h. `TerugkeertijdFactorenOndergrens_WegennetVoorbeeld1_2014_2085hoog_0.95.csv`

0	0.5	1	2	5	10	20	25	50	100	200	250
10	0.00798	0.00698	0.006	0.00491	0.00423	0.00365	0.00348	0.00296	0.00248	0.00203	0.00189
15	0.0095	0.00838	0.00727	0.00603	0.00526	0.00459	0.00438	0.00376	0.00316	0.0026	0.00244
30	0.0121	0.0108	0.00951	0.00804	0.00713	0.0063	0.00604	0.00523	0.00444	0.0037	0.00347
60	0.0144	0.0131	0.0116	0.01	0.00899	0.00803	0.00772	0.00675	0.00578	0.00485	0.00457
120	0.0161	0.0149	0.0134	0.0117	0.0106	0.00961	0.00927	0.00818	0.00706	0.00598	0.00564

i. TerugkeertijdFactorenBovengrens_WegennetVoorbeeld1_2014_2085hoog_0.95.csv

0	0.5	1	2	5	10	20	25	50	100	200	250
10	0.0121	0.0101	0.00863	0.00721	0.00637	0.0057	0.00552	0.00509	0.00484	0.00475	0.00476
15	0.0139	0.0117	0.0101	0.00861	0.00772	0.00704	0.00687	0.00649	0.00633	0.0064	0.00646
30	0.0174	0.0147	0.013	0.0113	0.0103	0.00963	0.00947	0.00921	0.00927	0.00965	0.00984
60	0.0208	0.0178	0.0158	0.014	0.013	0.0123	0.0122	0.0121	0.0124	0.0131	0.0134
120	0.0239	0.0206	0.0185	0.0166	0.0155	0.0149	0.0148	0.0148	0.0153	0.0164	0.0168

j. NeerslagFactoren_WegennetVoorbeeld1_2014_2085hoog_0.95.csv

0	0.5	1	2	5	10	20	25	50	100	200	250
10	3.713	3.356	3.109	2.88	2.752	2.651	2.623	2.545	2.481	2.427	2.412
15	3.912	3.525	3.261	3.019	2.886	2.781	2.752	2.672	2.607	2.553	2.537
30	4.05	3.659	3.394	3.153	3.021	2.918	2.89	2.813	2.75	2.698	2.683
60	3.943	3.603	3.369	3.155	3.037	2.945	2.92	2.851	2.796	2.749	2.736
120	3.647	3.391	3.21	3.04	2.945	2.87	2.849	2.793	2.747	2.708	2.698

k. NeerslagFactorenOndergrens_WegennetVoorbeeld1_2014_2085hoog_0.95.csv

0	0.5	1	2	5	10	20	25	50	100	200	250
10	3.448	3.063	2.779	2.493	2.321	2.175	2.132	2.01	1.901	1.803	1.773
15	3.624	3.205	2.898	2.592	2.408	2.252	2.207	2.076	1.96	1.855	1.823
30	3.746	3.316	3	2.685	2.494	2.331	2.283	2.146	2.024	1.913	1.879
60	3.652	3.27	2.981	2.685	2.502	2.344	2.297	2.162	2.04	1.929	1.895
120	3.39	3.092	2.856	2.601	2.439	2.295	2.252	2.126	2.011	1.904	1.872

l. NeerslagFactorenBovengrens_WegennetVoorbeeld1_2014_2085hoog_0.95.csv

0	0.5	1	2	5	10	20	25	50	100	200	250
10	3.998	3.678	3.479	3.326	3.262	3.23	3.225	3.223	3.239	3.269	3.281
15	4.222	3.878	3.671	3.516	3.458	3.433	3.431	3.44	3.468	3.513	3.53
30	4.379	4.038	3.839	3.702	3.659	3.653	3.657	3.686	3.737	3.806	3.831
60	4.257	3.97	3.808	3.707	3.687	3.701	3.712	3.76	3.83	3.919	3.951
120	3.922	3.719	3.608	3.552	3.555	3.589	3.605	3.668	3.752	3.852	3.888

Een laatste voorbeeld betreft het gehele hoofdwegennet van Nederland, omgezet naar een lokaal coördinatenstelsel en uitgedund. Het invoerbestand heeft de naam

wegennet4neerslagstat-Hoofdwegennet.csv. De kopregel bevat alleen de benaming Hoofdwegennet, dus er worden geen betrouwbaarheidsintervallen berekend en

klimaatscenario's blijven buiten beschouwing. Dit bestand wordt eerst weer gedupliceerd naar een bestand met de standaardnaam `wegennet4neerslagstat.csv`. De resultaten zijn als volgt.

m. TerugkeertijdFactoren_Hoofdwegennet.csv

0	0.5	1	2	5	10	20	25	50	100	200	250
10	0.000965	0.000965	0.000965	0.000965	0.000965	0.000965	0.000965	0.000965	0.000965	0.000965	0.000965
15	0.00108	0.00108	0.00108	0.00108	0.00108	0.00108	0.00108	0.00108	0.00108	0.00108	0.00108
30	0.00131	0.00131	0.00131	0.00131	0.00131	0.00131	0.00131	0.00131	0.00131	0.00131	0.00131
60	0.00158	0.00158	0.00158	0.00158	0.00158	0.00158	0.00158	0.00158	0.00158	0.00158	0.00158
120	0.00193	0.00193	0.00193	0.00193	0.00193	0.00193	0.00193	0.00193	0.00193	0.00193	0.00193
240	0.00236	0.00236	0.00236	0.00236	0.00236	0.00236	0.00236	0.00236	0.00236	0.00236	0.00236
360	0.00265	0.00265	0.00265	0.00265	0.00265	0.00265	0.00265	0.00265	0.00265	0.00265	0.00265
480	0.0029	0.0029	0.0029	0.0029	0.0029	0.0029	0.0029	0.0029	0.0029	0.0029	0.0029
720	0.00326	0.00326	0.00326	0.00326	0.00326	0.00326	0.00326	0.00326	0.00326	0.00326	0.00326

n. NeerslagFactoren_Hoofdwegennet.csv

0	0.5	1	2	5	10	20	25	50	100	200	250
10	4.484	3.944	3.57	3.223	3.029	2.876	2.833	2.717	2.62	2.538	2.515
15	5.005	4.387	3.964	3.576	3.362	3.194	3.147	3.021	2.916	2.829	2.803
30	5.624	4.939	4.474	4.051	3.82	3.64	3.59	3.456	3.346	3.255	3.228
60	5.763	5.124	4.684	4.28	4.059	3.886	3.839	3.71	3.605	3.518	3.493
120	5.416	4.911	4.554	4.217	4.03	3.882	3.841	3.729	3.638	3.563	3.541
240	4.88	4.499	4.221	3.953	3.801	3.679	3.645	3.553	3.477	3.413	3.395
360	4.538	4.212	3.97	3.735	3.6	3.491	3.46	3.377	3.308	3.25	3.234
480	4.289	3.995	3.775	3.559	3.434	3.333	3.305	3.229	3.174	3.13	3.117
720	3.948	3.689	3.493	3.299	3.197	3.124	3.104	3.052	3.019	2.996	2.99

Voor het gehele hoofdwegennet is de geschatte terugkeertijd van zeer zware neerslag ongeveer 300-1000 maal kleiner dan voor een enkel punt (dus een hoge neerslaghoeveelheid wordt 300 tot 1000 maal vaker ergens op het hoofdwegennet overschreden dan op een enkel punt). Echter, voor een gegeven terugkeertijd zijn de geschatte terugkeerwaarden van de zwaarste neerslag op het hele hoofdwegennet slechts 2.5-5.8 maal hoger dan de terugkeerwaarden van de neerslag op een enkel punt.

3.3 Code

Onderstaande R-code staat in het bestand RainRoadStat_2p1.R.

```
#
# Calculate the statistics of heavy precipitation on a selected part of the
# road network in the Netherlands
#
# Reference and manual:
# Bepaling van de statistiek van zware neerslag voor het Nederlandse wegennet
# - handleiding en technische achtergrond van versie 2.1.
# KNMI Technical Report (draft), De Bilt.
#
# Version 2.1
# cees.de.valk@knmi.nl
#

# current settings
version <- c(2, 1)

# minimum number of random footprints to be simulated
n <- 50000

# precipitation duration in minutes
tau <- c(10, 15, 30, 60, 120, 240, 360, 480, 720)

# footprint model parameters: point estimates and estimates from bootstrap sample
par1 <- c(0.0605722041592312, 0.0605722041592312, -0.0051595087059407, 0.164334311729998,
0.0122675529542287, 0.161889448929253, 0.00823591058416611, 0.0605722041592312,
0.0166407623513871, 0.0699586199618009, 0.0605722041592312, 0.213270103121524,
0.251148848985792, 0.308617199231731, 0.026210379467783, 0.0428035754719649,
0.122089073340515, 0.0722814200309778, 0.136400570559438, 0.00844175078051772,
0.00922591427119534, 0.042666931620399, 0.0605722041592312, -0.102849656654589,
0.0587762202920635, -0.0581340712586678, 0.026210379467783, 0.0732029541381365,
-0.00231370949825425, 0.199874683831417, -0.0821552540131022, -0.0220942717372203,
0.184353899652012, 0.132523873781827, 0.0293700298207638, -0.34152346159245,
0.197365218306339, 0.235741496143985, 0.00376279321433209, 0.217972867456719,
0.026210379467783, -0.0761085401422852, 0.0933112878701191, 0.198696136421446,
0.000422179073821727, 0.0441758021329399, 0.0605722041592312, -0.0447386519685618,
0.190473686908851, -0.102849656654589, 0.0428035754719649, 0.255104394387823,
0.255104394387823, 0.272308825159713, 0.239737935113966, 0.261635536770461,
0.230232409942055, 0.267150659157482, 0.255104394387823, 0.265888956678331,
0.248031588912098, 0.255104394387823, 0.215132097056039, 0.230310778233583,
0.228002588426924, 0.264098160232819, 0.256009140482185, 0.23813307697274,
0.262335648817324, 0.249520144322969, 0.265002906327181, 0.274309464432883,
0.252993212081827, 0.255104394387823, 0.286599077022657, 0.266107476310486,
0.284803558127491, 0.264098160232819, 0.247366815793551, 0.274515099175563,
0.22029026305827, 0.288830651220863, 0.270629302615457, 0.23825520715495,
0.241106479836369, 0.260920577783705, 0.350914533103633, 0.233430285342339,
0.230678401581347, 0.259868780445008, 0.231583147675709, 0.264098160232819,
0.287856057052154, 0.261294820854635, 0.23074416926897, 0.275963809578268,
```

```

0.249947944840844, 0.255104394387823, 0.27964539212526, 0.219548605400322,
0.286599077022657, 0.256009140482185)
par2 <- c(2.32328618643694, 2.11937728101085, 2.70896147429356, 2.01614783404518,
2.3376280291593, 2.16892887731324, 2.83976183253053, 2.29791980452258, 2.41524240698936,
2.3973961465704, 2.28449434377713, 2.10385983597082, 2.29463745131395, 2.15557929185449,
2.19321104213649, 2.59392600068591, 2.31094278473433, 2.02173882807678, 1.25559617156129,
2.35597043548513, 2.90577476485556, 1.91487076179601, 2.38308055365194, 1.78358185336165,
2.34361371137953, 2.04215025876949, 2.62681166424565, 2.19663224012304, 2.63503269074219,
2.22566042241329, 1.81914585650945, 2.46064383292021, 1.98211021923067, 1.93811044401466,
2.54581949751892, 2.70378141993688, 1.9735134286232, 1.58059264511377, 2.10122456911687,
1.76917844718682, 2.08365255640068, 2.14736576672251, 2.04983956665529, 1.62919120777803,
1.84108309270236, 2.30607428076479, 2.21712518175514, 2.16809972941111, 1.86457646567846,
1.67652498902738, 2.32535208564964, 0.127732050395563, 0.14791862250076,
0.0509692371089827, 0.147730230732031, 0.11237693144999, 0.145049386048786,
-0.00242556615713797, 0.145621923283339, 0.155790978832381, 0.0829319829724337,
0.114607354453933, 0.13217523575603, 0.12580792880833, 0.164767729138534,
0.12130546263172, 0.0588610384096338, 0.172954927327307, 0.174526998568497,
0.326580546193305, 0.070554497500727, 0.0430218048138041, 0.194919609263864,
0.108387161476892, 0.265830569632767, 0.0674215004785061, 0.179926447311274,
0.106944846235082, 0.152922536848842, 0.0335772497287214, 0.139294443756915,
0.26065260437856, 0.0825181797966884, 0.156697077019391, 0.202107180345173,
0.0180002188123916, 0.0391803787672462, 0.206708326142185, 0.273584635975371,
0.14580610429998, 0.219662849082796, 0.167181078566673, 0.115235630997562,
0.119867298702998, 0.255418932033512, 0.239997860831385, 0.110372675052793,
0.168562686498016, 0.204338061020857, 0.224110823944518, 0.262068621519985,
0.135578854864788)

# length and width of pixel
delta <- 900

# climate years/scenarios and corresponding correction factors for precipitation (for
durations
# less than or equal to 2 hours)
climates <- c("2014", "2030laag", "2030hoog", "2050laag", "2050hoog", "2085laag",
"2085hoog")
clfactor <- c(1.000, 1.039, 1.077, 1.039, 1.213, 1.064, 1.411)

# GP, not GLO! Otherwise severe overshoot possible
GP <- TRUE

# optional argument: assess sampling error in outcomes
dose <- FALSE # default: no error assessment

# no. of significant digits in output tables for return periods
# (for return values, it is one digit more)
dg <- 3

# print the version of this code
versionstring <- paste("version ", version[1], ".", version[2], sep= "")
print(versionstring)

# install packages

```

```

havesp <- require("sp")
if (!havesp) {
  install.packages("sp")
  havesp <- require("sp")
}

# function for simulating footprints
simratio <- function(x, y, l1, l2, n) {
  count1 <- 0
  count2 <- 0
  gap <- sqrt(l1^2+l2^2)/1.9
  mx <- max(x)
  my <- max(y)

  while (count1< n) {
    pb = txtProgressBar(min = 0, max = n, initial = 0)
    for (j in 1:n){
      point <- runif(2)*c(mx+2*gap, my+2*gap)-gap
      dir <- runif(1)*pi*2
      # attach <- c(l1/2, l2/2)
      R <- c(cos(dir), sin(dir), -sin(dir), cos(dir))
      dim(R) <- c(2, 2)
      point <- rep(point, each= 4)
      dim(point) <- c(4, 2)

      pol1 <- c(0, l1, l1, 0) - l1/2
      pol2 <- c(0, 0, l2, l2) - l2/2
      pol <- cbind(pol1, pol2)%*%R + point

      id <- point.in.polygon(x, y, pol[, 1], pol[, 2])

      count1 <- count1 + max(id)
      count2 <- count2 + sum(id)
      setTxtProgressBar(pb, j)
    }
    print(paste("progress:", count1/n))
  }
  factor <- count2/(length(x)*count1) # correction factor for RETURN PERIODS (<= 1)
}

# read position data in metres from file with standard name and format
# read also header information
Data <- data.matrix(read.csv(file= "wegennet4neerslagstat.csv", header= FALSE, skip= 1))
Data <- Data[!is.na(Data[, 1]+Data[, 2]), ]
dim(Data) <- c(length(Data)/2, 2)

# read header and interpret the information it contains
pn <- clid0 <- clid1 <- NA
a <- header <- scan(file= "wegennet4neerslagstat.csv", nlines= 1, what= "character", sep=
",")
la <- length(a)
if (la> 1) {

```

```

b <- rep(NA, la)
for (i in 1:7) {
  id <- grepl(climates[i], a)
  b[id] <- i
}
ind <- which(b>0)
b <- b[ind]
if (length(b)== 2) {
  clid0 <- b[1]
  clid1 <- b[2]
}
a[1] <- NA
a[ind] <- NA
b <- as.numeric(a[!is.na(a)])
if (length(b)== 1) {
  pn <- as.numeric(b)
}
}
if (is.numeric(pn) & pn< 1 & pn> 0) {
  dose <- TRUE
} else {
  print("Confidence intervals are not computed.")
}
# for output name without blanks
header <- gsub(" ", "", paste(header, collapse= "_"), fixed = TRUE)

# factors for converting between climates
alpha0 <- alpha1 <- 1
if (is.numeric(clid0) & clid0>= 1 & clid0<= 7) {
  alpha0 <- clfactor[clid0]
}
if (is.numeric(clid1) & clid1>= 1 & clid1<= 7) {
  alpha1 <- clfactor[clid1]
}

# estimated width and length of footprint in pixels (point estimator and bootstrap
sample)
ntau <- length(tau)
l1coeff <- t(par1)
l2coeff <- t(par2)
ndraw <- length(l1coeff)/2-1
dim(l1coeff) <- dim(l2coeff) <- c(ndraw+1, 2)
if (!dose) {
  l1coeff <- array(l1coeff[1, ], dim= c(1, 2))
  l2coeff <- array(l2coeff[1, ], dim= c(1, 2))
  ndraw <- 0
}
nsim <- ndraw*25

# point estimates
l1 <- l2 <- array(NA, dim= c(ntau, ndraw+1))
for (i in 1:ntau) {

```

```

l1[i, ] <- exp(l1coeff[, 1])*tau[i]^l1coeff[, 2]
l2[i, ] <- exp(l2coeff[, 1])*tau[i]^l2coeff[, 2]
}

# read position data in metres from file with standard name and forma
x <- Data[, 1]
y <- Data[, 2]

# rasterize the position data
x <- round((x-min(x))/delta)
y <- round((y-min(y))/delta)
xy <- unique(cbind(x, y))

# loop over durations tau to compute correction factors for RETURN PERIODS
factor <- array(NA, dim= c(ntau, ndraw+1))
for (i in 1:ntau) {
  print(i)
  factor[i, 1] <- simratio(xy[, 1], xy[, 2], l1[i, 1], l2[i, 1], n)
}
factor.ens <- factor
if (ndraw > 0) {
  n1 <- round(n/10) # faster less precise simulation for error analysis
  for (i in 1:ntau) {
    print(i)
    for (j in 1:ndraw) {
      j1 <- j+1
      factor[i, j1] <- simratio(xy[, 1], xy[, 2], l1[i, j1], l2[i, j1], n1)
    }
  }
  F <- log(factor) # better represented by normal distribution
  lfactor.sd <- apply(F, 1, sd)
  Fm <- apply(F, 1, mean)
  sF <- svd(F-rep(Fm, ndraw+1))
  U <- sF$u[, 1:2]*%*%diag(sF$d[1:2])/sqrt(ndraw+1)
  N <- rnorm(nsim*2)
  dim(N) <- c(2, nsim)
  factor.ens <- cbind(factor[, 1], exp(U*%*%N+rep(Fm, nsim)))
}

# Code voor STOWA (2019) rapport voor het klimaat van 2014
STOWA2019_lang <- function(RP, tau0) {
  # duration D is in hours, tau0 in minutes!!!
  # Is beschreven als GEV in rapport, maar is de GP verdeling!
  D <- tau0/60
  seriesT <- RP
  row <- 0
  R <- rep(NA, length(seriesT))
  for (T in seriesT) {
    row <- row + 1
    if (D > 12 & D <= 240) {
      # Locatieparameter:
      Mu <- 1.02 * (0.239 -0.0250 * log(D))^(1/-0.512)

```

```

# Dispersiecoefficient:
Gamma <- 0.478 -0.0681 * log10(D*60)
# Vormparameter
Theta <- 0.118 -0.266 * log10(D*60) + 0.0586 * (log10(D*60))^2
R[row] <- Mu * (1 + Gamma * (1-T^(-1*Theta))/Theta)
}
}
Value <- R
}
STOWA2019_kort <- function(RP, tau0) {
# Tabel 2 van STOWA-rapport 2018 reproduceren (blz. 23), maar nu dus
# bijgewerkt o.b.v. STOWA2019 (tabel 2 van nieuwe deelrapport):
D <- tau0 # duration in minutes, scalar
seriesT <- RP
row <- 0
R <- rep(NA, length(seriesT))
for (T in seriesT) {
row <- row + 1
# Vormparameter:
if ((D >= 10 & D <= 90) | (D > 90 & D <= 720 & T <= 120)) {
Theta <- -0.0336 - 0.264 *log10(D)+0.0636*(log10(D))^2
}
if (D > 90 & D <= 720 & T > 120) {
Theta <- -0.310 - 0.0544 *log10(D)+0.0288*(log10(D))^2
}
# Locatieparameter:
Mu <- 7.339 + 0.848*log10(D)+2.844*(log10(D))^2
# Dispersiecoefficient:
if (D >= 10 & D <= 104) {
Gamma <- 0.04704 + 0.1978 * log10(D) - 0.05729*(log10(D))^2
}
if (D > 104 & D <= 720) {
Gamma <- 0.2801 - 0.0333 * log10(D)
}
Beta <- Gamma * Mu
x <- Mu + Beta/Theta * (1 - ((1-exp(-1/T))/exp(-1/T))^Theta)
# Voor herhalingstijden van 121 tot 165 jaar, worden door die aanpassing
# van de vormparameter de neerslagvolumes bij een bepaalde duur kleiner dan
# bij een herhalingstijd van 120 jaar. Deze inconsistentie kan worden opgelost
# door in voorkomende gevallen het grootste neerslagvolume te nemen:
if (D > 90 & D <= 720 & T > 120 & T <= 165) {
x120 <- Mu + Beta/Theta * (1 - ((1-exp(-1/120))/exp(-1/120))^Theta)
x <- max(x, x120)
}
# Verhoog regensom met 2% vanwege onderschatting van automatische regenmeters t.o.v.
handregenmeters:
R[row] <- x * 1.02
}
Value <- R
}

```

```

# The following is the GP tail fits based on research described in STOWA (2019) but is
not their final result!
# Asymptotic approximations are used
STOWA2019_GP <- function(RP, RVGLO, loc, tau0, N) {
  # loc is the 1-year return value
  # RVGLO are GLO return values corresponding to return periods RP
  # RP is a vector; tau0 is a scalar
  # nGEV <- 436 # no. of annual maxima from STOWA (2018)
  gamm <- -(0.118 - 0.266*log10(tau0) + 0.0586*(log10(tau0))^2)
  disp <- 0.478 - 0.0681*log10(tau0)
  euler <- 0.5772157

  rpmax <- 150
  # id <- RP<= rpmax
  id <- RP<= rpmax & RVGLO>= loc # only difference with version 2.0
  if (tau0< 120) {
    UU <- RVGLO[id]/loc # threshold at 1/year
    hh <- (RP[id]^gamm-1)/gamm
    disp <- sum((UU-1)*hh)/sum(hh^2) # dispersion coefficient fitted to GLO quantiles
  }
  # return values (GP at threshold exceeded once per year)
  hh <- (RP^gamm-1)/gamm
  scale <- disp*loc
  rv0 <- loc+scale*hh # nominal estimates
  rv <- NULL

  nsim <- dim(N)[2]
  if (nsim> 0) {
    fpar <- function(p, xpar) {
      loc <- p[1]
      scale <- p[2]
      shape <- p[3]
      list(loc = loc, scale = scale, shape = shape)
    }
    rv <- array(NA, dim= c(length(RP), nsim))
    for (j in 1:nsim) {
      data <- loc+(scale/gamm)*(N[, j]^(-gamm)-1)
      fit <- fgev.flex(data, c(loc, scale, gamm), fpar, NULL)
      p1 <- fit$est
      loc1 <- p1[1]
      scale1 <- p1[2]
      gamm1 <- p1[3]
      rv[, j] <- loc1+(scale1/gamm1)*(RP^gamm1-1)
    }
  }

  # nominal estimate first (always a matrix!)
  rv <- cbind(rv0, rv)
}
#
# Flexible ML estimator for GEV from Chris Ferro <c.a.t.ferro@reading.ac.uk> 14 August
2006

```

```

#
fgev.flex <- function(data, start, fpar, xpar, std.err = TRUE, ...) {
  nll.gev <- function(par) {
    pmat <- fpar(par, xpar)
    loc <- pmat$loc
    scale <- pmat$scale
    shape <- pmat$shape
    if(any(scale <= 0)) return(1e+20)
    gumbel <- (abs(shape) < 1e-06)
    y <- (data-loc)/scale
    z <- 1 + shape*y
    if(any(z <= 0, na.rm = TRUE)) return(1e+20)
    nll <- (1 + 1 / shape) * log(z) + z^(-1 / shape)
    nll[gumbel] <- y[gumbel] + exp(-y[gumbel])
    sum(nll + log(scale), na.rm = TRUE)
  }
  call <- match.call()
  opt <- optim(start, nll.gev, hessian = std.err, ...)
  gev <- fpar(opt$par, xpar)
  out <- list(estimate = opt$par, std.err = rep(NA, length(opt$par)), cov = NULL,
deviance = 2 * opt$value, convergence = opt$convergence, counts = opt$counts, message =
opt$message, loc = gev$loc, scale = gev$scale, shape = gev$shape)
  cmat <- try(solve(opt$hessian), TRUE)
  if(!inherits(cmat, "try-error")) {
    out$std.err <- sqrt(diag(cmat))
    out$cov <- cmat
  }
  structure(c(out, call = call), class = "evd")
}

# standard return periods for the given climate scenario
RP <- c(0.5, 1.0, 2.0, 5.0, 10.0, 20.0, 25.0, 50.0, 100.0, 200.0, 250.0)
RV <- array(NA, dim= c(ntax, length(RP), nsim+1))

# return periods to build table to interpolate in
rp <- 10^(log10(0.005)+(7-log10(0.005))*(0:2000)/2000)
lrp <- length(rp)

# create table of return values according to STOWA (2019): either GLO, or (if GP) GP
rv <- array(NA, dim= c(lrp, nsim+1))
RV0 <- RP1 <- RP0 <- array(NA, dim= dim(RV))
RVfix <- RPlfix <-array(NA, dim= dim(RV))

# N <- rnorm(nsim*3) # GEV parameter "noise"
# dim(N) <- c(3, nsim)
nGEV <- 436 # no. of annual maxima from STOWA (2018)
N <- -log(runif(nGEV*nsim)) # exponentially distributed random variables
dim(N) <- c(nGEV, nsim)

for (j in 1:ntax) {
  tau0 <- tau[j]
  print(tau0)
}

```



```

if (tau0 < 1440) {
  rv <- STOWA2019_kort(rp, tau0) # GLO
  loc <- STOWA2019_kort(1, tau0) # GLO
} else {
  rv <- STOWA2019_lang(rp, tau0) # GLO
  loc <- STOWA2019_lang(1, tau0) # GLO
}
if (GP) {
  # take GP shape from update in Section 2.2 of STOWA (2019) as in STOWA2019_lang above
  # fit GP dispersion coefficient to quantiles of GLO computed above
  # take GP location equal to GLO location
  rv <- STOWA2019_GP(rp, rv, loc, tau0, N)
}
RVref <- approx(log(rp), rv[, 1], log(RP))$y

# the year/scenario combinations are accounted for by alpha0 and alpha1
for (i in 1:(nsim+1)) {
  RV[j, , i] <- alpha1*approx(log(rp*factor.ens[j, i]), rv[, i], log(RP))$y
  RVfix[j, , i] <- alpha1*approx(log(rp*factor.ens[j, 1]), rv[, i], log(RP))$y
  RV0[j, , i] <- alpha0*approx(log(rp), rv[, i], log(RP))$y

  RP1[j, , i] <- exp(approx(rv[, i]*alpha1, log(rp), RVref*alpha0)$y)*factor.ens[j, i]
  RP0[j, , i] <- RP
  RP1fix[j, , i] <- exp(approx(rv[, i]*alpha1, log(rp), RVref*alpha0)$y)*factor.ens[j,
1]
}
}

# force RV to increase with increasing duration tau
RV <- apply(RV, c(2, 3), cummax)
RVfix <- apply(RVfix, c(2, 3), cummax)

# conversion between different climates is only possible for tau <= 120
if (alpha1 != alpha0) {
  id <- tau <= 120
  RV <- RV[id, , , drop= FALSE]
  RVfix <- RVfix[id, , , drop= FALSE]
  RV0 <- RV0[id, , , drop= FALSE]
  RP1 <- RP1[id, , , drop= FALSE]
  RP1fix <- RP1fix[id, , , drop= FALSE]
  RP0 <- RP0[id, , , drop= FALSE]
  tau <- tau[id]
  ntau <- length(tau)
}

# standard deviations of confidence intervals
if (!is.na(pn)) {
  p0 <- (1-pn)/2
  qn <- qnorm(1-p0) # lognormal approximation is fine!!
  # RVmu <- apply(RV, c(1, 2), mean, na.rm= TRUE)
  # RVlb <- apply(RV, c(1, 2), quantile, p0, na.rm= TRUE)*(RV[, , 1]/RVmu)

```

```

# RVub <- apply(RV, c(1, 2), quantile, 1-p0, na.rm= TRUE)*(RV[, , 1]/RVmu)
RVrsd <- apply(log(RV), c(1, 2), sd, na.rm= TRUE)
RVlb <- RV[, , 1]*exp(-RVrsd*qn)
RVub <- RV[, , 1]*exp(RVrsd*qn)
# RVfixrsd <- apply(log(RVfix), c(1, 2), sd, na.rm= TRUE)
# RVfixlb <- RVfixl*exp(-RVfixrsd*qn)
# RVfixub <- RVfixl*exp(RVfixrsd*qn)
# RV0rsd <- apply(log(RV0), c(1, 2), sd, na.rm= TRUE)
# RV0lb <- RV0[, , 1]*exp(-RV0rsd*qn)
# RV0ub <- RV0[, , 1]*exp(RV0rsd*qn)
factorub <- factor[, 1]*exp(lfactor.sd*qn)
factorlb <- factor[, 1]*exp(-lfactor.sd*qn)
RP1rsd <- apply(log(RP1), c(1, 2), sd, na.rm= TRUE)
RP1lb <- RP1[, , 1]*exp(-RP1rsd*qn)
RP1ub <- RP1[, , 1]*exp(RP1rsd*qn)
RP1fixrsd <- apply(log(RP1fix), c(1, 2), sd, na.rm= TRUE)
RP1fixlb <- RP1fix[, , 1]*exp(-RP1fixrsd*qn)
RP1fixub <- RP1fix[, , 1]*exp(RP1fixrsd*qn)
}

# output of table for the current (2014) climate
Table <- rbind(c(0, RP), cbind(tau, signif(RV[, , 1]/RV0[, , 1], digits= dg+1)))
write.table(Table, file= paste("NeerslagFactoren_", header, ".csv", sep= ""),
            sep= ",", row.names= FALSE, col.names= FALSE)
if (dose) {
  Table <- rbind(c(0, RP), cbind(tau, signif(RVlb/RV0[, , 1], digits= dg+1)))
  write.table(Table, file= paste("NeerslagFactorenOndergrens_", header, ".csv", sep= ""),
              sep= ",", row.names= FALSE, col.names= FALSE)
  Table <- rbind(c(0, RP), cbind(tau, signif(RVub/RV0[, , 1], digits= dg+1)))
  write.table(Table, file= paste("NeerslagFactorenBovengrens_", header, ".csv", sep= ""),
              sep= ",", row.names= FALSE, col.names= FALSE)
}
TableRP <- rbind(c(0, RP), cbind(tau, signif(RP1[, , 1]/RP0[, , 1], digits= dg)))
write.table(TableRP, file= paste("TerugkeertijdFactoren_", header, ".csv", sep= ""),
            sep= ",", row.names= FALSE, col.names= FALSE)
if (dose) {
  TableRP <- rbind(c(0, RP), cbind(tau, signif(RP1lb/RP0[, , 1], digits= dg)))
  write.table(TableRP, file= paste("TerugkeertijdFactorenOndergrens_", header, ".csv",
  sep= ""),
              sep= ",", row.names= FALSE, col.names= FALSE)
  TableRP <- rbind(c(0, RP), cbind(tau, signif(RP1ub/RP0[, , 1], digits= dg)))
  write.table(TableRP, file= paste("TerugkeertijdFactorenBovengrens_", header, ".csv",
  sep= ""),
              sep= ",", row.names= FALSE, col.names= FALSE)
}

```

Literatuur

- Lochbihler, K., Lenderink, G., Siebesma, A. P. (2017), The spatial extent of rainfall events and its relation to precipitation scaling, *Geophys. Res. Lett.*, 44, 8629–8636.
- STOWA (2019) (auteurs: Beersma, J., Hakvoort, H., Jilderda, R., Overeem, A. & Versteeg, R.), Neerslagstatistiek en reeksen voor het waterbeheer 2019. STOWA rapport 2019-19, Stichting Toegepast Onderzoek Waterbeheer, Amersfoort.

Bijlage: Technische achtergrond

Spatiotemporal statistics of extreme sub-daily precipitation derived from weather radar data

Cees de Valk, Aart Overeem

KNMI, PO Box 201, 3730 AE De Bilt, The Netherlands, cees.de.valk@knmi.nl

Abstract

For a single site (of a rain gauge, say), the statistics of extreme precipitation are conveniently summarized by depth-duration-frequency (DDF) curves. Considering a spatial domain of some extent, one may ask: how often does it happen that the precipitation depth accumulated over 10 min exceeds 60 mm somewhere on this domain? Naturally, this frequency is higher than the frequency of exceedance of the same depth at a site; it depends on the size and shape of the domain and on the spatial dependence of extreme precipitation. In the present study, statistics describing the spatial dependence of extreme precipitation are estimated from 11 years of gauge-adjusted radar precipitation data collected over the Netherlands, assuming spatial homogeneity. These statistics are the values of the extremal coefficient function (ECF) for selected spatial domains. From these values, a simple model is derived for converting the DDF relation to return values of the highest precipitation depth within an arbitrary spatial domain, for durations from 10 min to 12 h. Confidence intervals are predicted using bootstrapping. The model is checked for fitness for its application to the design and maintenance of the drainage of highways, and the scope for further improvement is discussed.

Keywords: Precipitation, Spatial statistics, Extreme value statistics, Weather radar, Depth-duration-frequency curve, Highway drainage

PACS: 92.40.Zg, 91.62.Ty

2000 MSC: 62G32, 62M30

1. Introduction

For any given site, the statistics of extreme precipitation are captured effectively by depth-duration-frequency (DDF) curves, specifying the relationship between precipitation depth, the time span ("duration") over which it has been accumulated, and its frequency of exceedance (or its return period, the reciprocal of frequency); [1, 2] are early examples of estimates for durations from 5 min to

24 h. These statistics (also presented in the equivalent form of intensity-duration-frequency curves) are usually derived from rain gauge measurements, often from several adjacent sites. However, in many applications, practically useful statistics of extreme precipitation also need to account for its spatial dependence. A familiar example is flood risk assessment for a catchment, which requires statistics of extremes of precipitation accumulated over (a) certain area(s) and durations(s), whereas the available precipitation data are usually rain gauge measurements.

The present study tackles a different and even more challenging problem: to determine the statistics of the maximum of precipitation depth over a given spatial domain and number of years, for a given duration. It was spurred by a question related to the design and maintenance of the drainage of highways. For long-term planning of the highway infrastructure, engineers in the Ministry of Infrastructure and Water Management of the Netherlands are considering the trade-offs between the risk posed by extreme precipitation in a changing climate and the cost of measures to reduce this risk for the entire network of highways and its critical elements, such as tunnels [3]. This leads them to questions such as "how often is the 10-yr value of precipitation accumulated over 10 min for a single site exceeded somewhere on a given part of the highway network?". Such questions have received little attention in the environmental sciences literature until now. To answer them, we need a suitable mathematical framework and suitable data.

The majority of studies of the spatial dependence of extreme precipitation to date are based on rain gauge data, e.g. [4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15]. Such datasets are available for many countries and regions. For modelling of spatial dependence over a wide range of spatial scales (as needed when considering highway networks), their main limitation is the low effective spatial resolution; the distances separating rain gauges are usually larger than the typical scale of heavy convective precipitation [16]. Therefore, they may not capture the true spatial patterns of heavy precipitation [10].

The present study takes a different approach: statistics of spatial patterns of heavy precipitation are derived from gauge-adjusted high-resolution radar precipitation data collected over the land area of the Netherlands [18, 19]. At a fixed point in space, these data are of lower quality than in-situ measurements. However, their high spatial resolution of about 1 km resolves convective events, which is a great advantage for studying the spatial dependence of extreme short-duration precipitation. The data are described in Section 2.

A mathematical framework for modelling spatiotemporal extremes is the max-stable process [20, 21, 6]. The max-stable process describes the statistics of the pointwise maximum of precipitation over a long time-interval, regarded as a random function of position. It is a direct generalization of the univariate extreme value distributions [22, 21]. Just as the latter, a max-stable process model en-

ables stable extrapolation of probabilities of precipitation events represented in the dataset towards more severe and rare versions of these events.

In Section 3, a simple model of the spatial dependence of precipitation extremes consistent with a max-stable process is introduced. Its parameters represent the size and shape of the stylized footprint of a heavy downpour over its lifetime for every duration between 10 min and 12 h (see Section 3). These parameters are derived from estimates of a set function, the extremal coefficient function (ECF) from [23]. Assuming spatial homogeneity, the ECF ξ_S approximates for every spatial domain S the ratio of

- a. the frequency that somewhere in S , the precipitation within a given duration exceeds some high (but otherwise arbitrary) level a , and
- b. the frequency that the same level a is exceeded in a single point.

The estimates are derived from 11 years of radar precipitation data (Section 4). The fitted model can subsequently be used to predict the ECF for arbitrary bounded sets of radar pixels of arbitrary shape and size (see Section 5). This makes it particularly suitable for estimation of the statistics of the heaviest precipitation within a chosen spatial domain. In the application to highway networks, the predicted ECF for the radar pixels covering a highway network is combined with a DDF relation derived from rain gauge data (see Section 6).

Alternatives to max-stable models exist for describing tail dependence, also in a spatial setting [24]. Such models appear to be more effective than max-stable models for extreme precipitation on large spatial scales: [4, 25, 26, 8, 9, 10, 14] find that precipitation maxima at sites separated by more than a few kilometres are asymptotically independent (i.e., the dependence eventually vanishes when increasing the length of time over which these maxima are taken; see [21]), which implies that max-stable models are biased on these scales. However, the max-stable process (and in particular, its ECF) offers by far the simplest and most straightforward way to predict the statistics of spatiotemporal extremes, so it is sensible to try this model first.

In Sections 5-7, the consistency of the model with available data is examined, and the scope for further improvement is discussed.

2. Data

The radar precipitation data sets were obtained with a spatial resolution of approximately 0.9 km² and a temporal resolution of 5 min. These data sets are based on the data of the two ground-based C-band weather radars operated by KNMI. For various reasons, the effective resolution may be somewhat lower. Rain gauge data from the KNMI automated weather stations and the network operated by volunteers were employed to adjust the radar precipitation depths. A

daily spatial adjustment employing the manual rain gauge data was combined with an hourly mean-field bias adjustment employing the automatic rain gauge data. More information on the derivation and quality of this gauge-adjusted radar precipitation product can be found in [18, 19, 27]. The data can be obtained from https://dataplatfom.knmi.nl/catalog/datasets/index.html?x-dataset=rad_nl25_rac_mfbs_5min&x-dataset-version=2.0.

The 5-min precipitation maps were accumulated to precipitation depth (in mm) over durations of 15, 30, 60 and 90 min and 2, 3, 4, 6, 8 and 12 h for every radar pixel. For the years 2008-2018, these data were processed to obtain 11 annual maxima of the precipitation depth for each of these durations at every pixel. At a very small fraction of the pixels, no valid values are given because some measurements were flagged as contaminated by non-meteorological echos. These pixels were ignored in the subsequent analysis.

The positions of the pixels are somewhat irregular, possibly as a result of a prior coordinate transformation combined with rounding. Therefore, the data were mapped to a pre-defined regular grid of 900 m resolution in a local UTM coordinate system (epsg:32631) by associating with each grid point the data of the nearest radar pixel if the latter is within 900 m. As an example, Figure 1 shows the maps of the annual maximum of 30-min precipitation thus obtained for each of the years 2008-2018.

Prominent in many of these images are narrow streaks, apparently generated by the movement of a localized heavy downpours over their lifetimes. Also notable is the striking dissimilarity of the patterns of different years. For example, in certain years, the streaks appear to be more narrow or wider than in other years, or seem to have different orientations, or the heavy precipitation is concentrated in different areas. One may suspect that the shapes and sizes of the spatial footprints of heavy precipitation in a particular year depend on the prevailing type of ambient weather conducive to heavy precipitation. Studying such relationships could be an interesting topic for further research.

In addition, wave-like features can be seen in some images. A check of the original data revealed that these are artefacts caused by fast moving squall lines; an example is shown in Figure 9.12 of [28].

For every duration, only the 10% highest of the annual precipitation maxima were used in the subsequent analysis: for the application (Section 1), the main interest is in precipitation depths with local return periods of 10 yr or more. Wave-like artefacts appear to be almost absent in the maps of annual maxima in this range, except for the map for 2010 and a duration of 15 min.

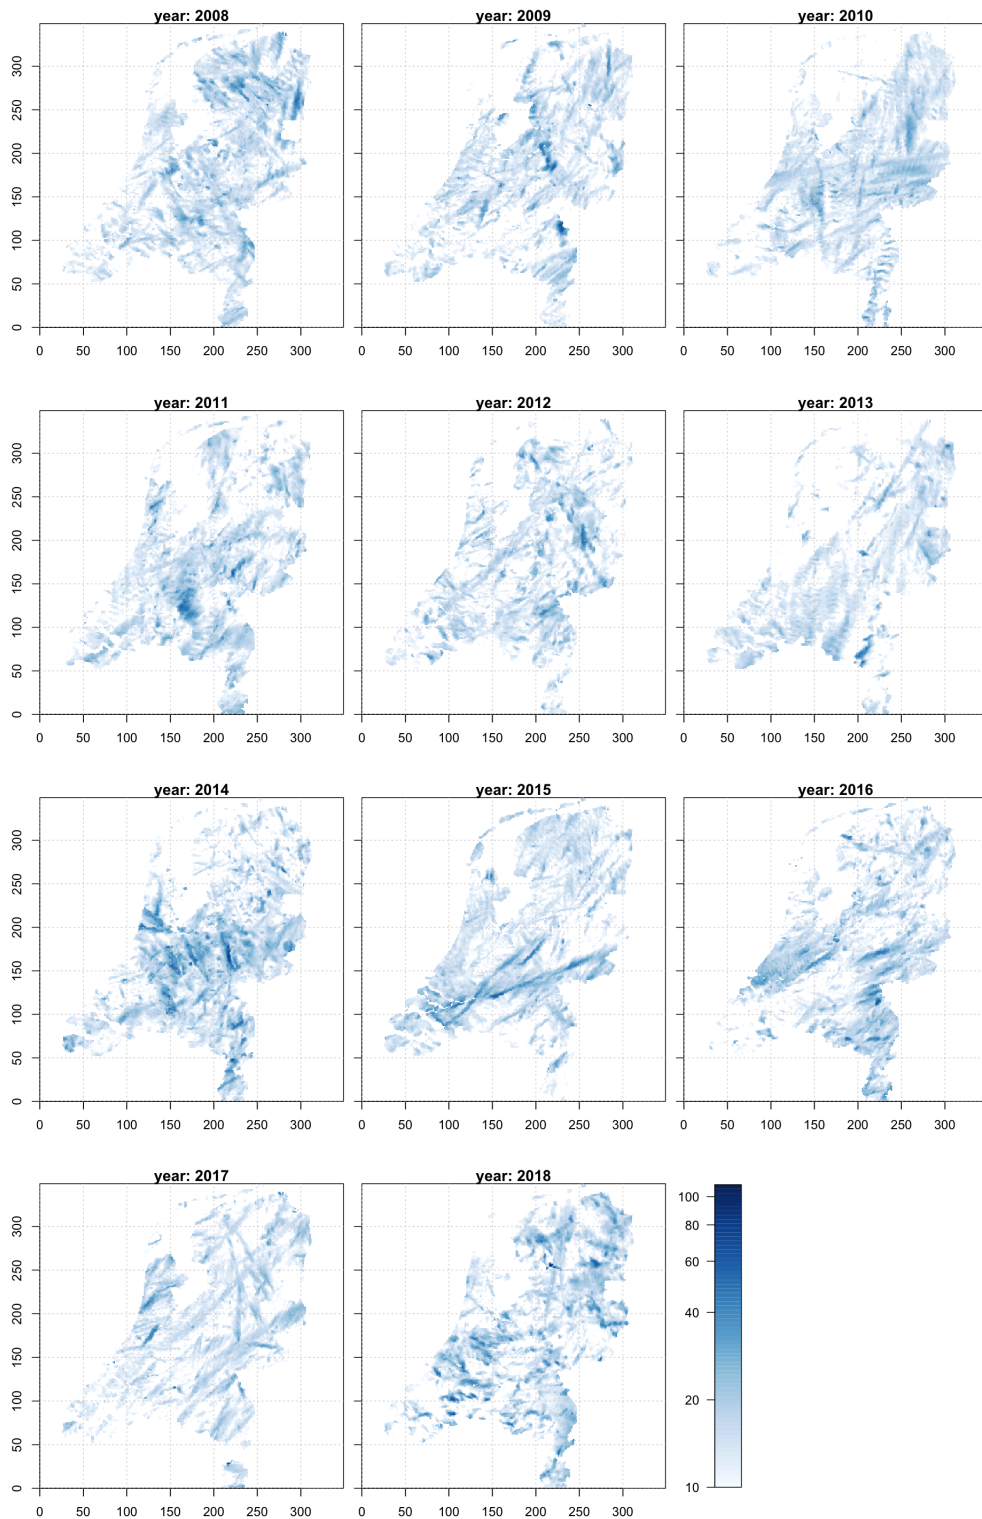


Figure 1: Maps of the annual maximum of 30-min precipitation (mm) (see colourbar) derived from weather radar data for each of the years 2008-2018. Axis unit is 1 pixel width (900 m).
5

3. A simple model of the spatial dependence of extreme precipitation

Spatial patterns of extreme precipitation are modelled with the resolution of a radar pixel. The statistics of sub-daily heavy precipitation is treated as uniform over the land area of the Netherlands. This may not be strictly true; an analysis of an earlier 11-year dataset of precipitation derived from radar data [19] indicates spatial variation in the location parameter of the distribution function of annual maxima. For durations of 6-12 h, the present dataset shows elevated values of the average annual precipitation in an area near the coast, consistent with the pattern of the location parameter shown in [19] for a duration of 24 h. However, for shorter durations, this pattern is not found. It is also missing in the maps of the 11-year maxima, indicating that it may be associated with predominantly moderately severe events. The statistics of extreme sub-daily precipitation currently in use in the Netherlands [29] neglects inhomogeneity.

Let \mathcal{F}_a be the spatial footprint of a cluster of heavy precipitation (downpour, rainstorm) consisting of the pixels where precipitation depth accumulated over a given duration has exceeded some value a . The downpour may move with the ambient circulation, but only the footprint accumulated over its lifetime is of interest.

Let S be a given set of radar pixels, for example the minimal set covering a network of roads. Consider the event that precipitation at some pixel in S exceeds the value a , or in other words: \mathcal{F}_a overlaps with S . Let a be high, so this is a rare event. The instants at which it occurs (say, the onsets of the events) are conventionally approximated by a Poisson process [30, 31]. It is loosely defined by the following properties:

- a. the number of events in a time-interval (t_0, t_1) and the number of events in a time-interval (t_2, t_3) with $t_2 > t_1$ are independent;
- b. two events cannot occur at approximately the same time.

The motivation for this approximation is that for a wide class of stochastic processes, the instants of the clusters of values exceeding a value a within a time interval Δ approach a Poisson process if $\Delta \rightarrow \infty$ while a increases in such way that the mean number of events in Δ tends to a constant; see e.g. [32] for stationary processes. In the context of weather, we may assume that the mean number of events in a time-interval of fixed length is seasonal, with a period of one year. Because only integer numbers of years Δ will be considered, the seasonality can be further ignored.

Under the Poisson approximation, the number $N_{S,a}(\Delta)$ of events of \mathcal{F}_a overlapping with S in Δ full years has the Poisson distribution

$$\mathbb{P}(N_{S,a}(\Delta) = k) = \frac{(\Delta\Lambda_{S,a})^k}{k!} e^{-\Delta\Lambda_{S,a}}, \quad (1)$$

in which $\Lambda_{S,a}$ is the mean number of such events per year (the frequency), a positive number. Let $p_S(\Delta)$ denote the highest precipitation in Δ years and over all pixels in S . Then (1) implies the approximation

$$\mathbb{P}(p_S(\Delta) \leq a) = \mathbb{P}(N_{S,a}(\Delta) = 0) = e^{-\Delta\Lambda_{S,a}}, \quad (2)$$

and for the case of a single pixel (by homogeneity, it does not matter which one), this reduces to

$$\mathbb{P}(p_0(\Delta) \leq a) = e^{-\Delta\Lambda_{0,a}}, \quad (3)$$

with $p_0(\Delta)$ the largest precipitation in Δ years at a single pixel, and $\Lambda_{0,a}$ the frequency that precipitation exceeds a at a single pixel.

Furthermore, assume that if the precipitation depth a increases to infinity, then the ratio $\Lambda_{S,a}/\Lambda_{0,a}$ tends to a constant ξ_S ; evidently, $\xi_S \geq 1$. Combined with (2) and (3), this gives the approximation

$$\frac{\log \mathbb{P}(p_S(\Delta) \leq a)}{\log \mathbb{P}(p_0(\Delta) \leq a)} = \Lambda_{S,a}/\Lambda_{0,a} = \xi_S \quad (4)$$

for large Δ and large a compatible with Δ .

If ξ_S is known, then the frequency $\Lambda_{S,a}$ of a precipitation depth larger than a accumulating somewhere on S can be approximated by $\Lambda_{0,a}\xi_S$. This decomposition of $\Lambda_{S,a}$ is very convenient: the factor ξ_S represents the influence of the spatial variability of heavy precipitation over S (and does not depend on the value of precipitation depth), and the factor $\Lambda_{0,a}$ represents the dependence on precipitation depth.

Regarding ξ_S as a function of S (in this case: as a set function defined on all subsets of pixels covering the Netherlands), it is known as the extremal coefficient function (ECF) [23, 33, 34]. For a set of radar pixels S , ξ_S can take values from 1 (in the case that the maxima in individual pixels in S are fully dependent) to $|S|$, the number of pixels in S (in the case that these maxima are independent). By homogeneity, the ECF satisfies $\xi_{S+x} = \xi_S$ for every difference vector x between two pixels. It generalizes the limiting value of the bivariate statistic

$$\frac{\log \mathbb{P}(p_0(\Delta) \leq a, p_x(\Delta) \leq a)}{\log \mathbb{P}(p_0(\Delta) \leq a)} \quad (5)$$

as a function of the spatial translation x , first proposed in [4]; (5) is ξ_S for $S = \{0, x\}$.

The ECF ξ is an object of a very high dimension, so in practice, it is not feasible to estimate it directly from the radar precipitation data without additional assumptions. These assumptions are cast in the form of a highly schematic model of the statistics of the footprint \mathcal{F}_a of precipitation depth exceeding a . In the

model, the footprint is a spatial object f of fixed shape and size, rotated (R_θ) over a random angle θ and translated over a random vector x :

$$\mathcal{F}_a = x + R_\theta f, \quad (6)$$

The object f and the statistics of x and θ are assumed to be the same for all $a > 0$; this ensures that ξ_S is indeed independent of a as assumed in (4). We may therefore speak of simulating a footprint \mathcal{F} rather than \mathcal{F}_a . The dependence structure specified by this simple model is compatible with a class of max-stable models proposed by Richard Smith in [34].

Because the statistics of precipitation are assumed to be spatially homogeneous, x in (7) must be uniformly distributed over a sufficiently large domain Ω_S containing S . For f , a rectangle is chosen with length and width depending on the duration of precipitation. The angle θ is uniformly distributed over $[-\pi, \pi]$.

For given values of the width and length of the rectangular f , the value of ξ_S for an arbitrary set of pixels S can now be obtained by simulation as follows:

1. draw a random midpoint x of the footprint \mathcal{F} from the uniform distribution on Ω_S ;
2. draw a random angle θ and compute \mathcal{F} by (6);
3. determine the number of n_S of pixels in S covered by \mathcal{F} , with the indicator i_S which equals 1 if $n_S > 0$, and 0 otherwise.

This simulation is repeated a large number of times, and the expectations $\mathbb{E}n_S$ and $\mathbb{E}i_S$ of n_S and i_S are estimated by their averages. Let $|S|$ denote the number of pixels in S . By the "mass balance" $\Lambda_{S,a}\mathbb{E}n_S = |S|\Lambda_{0,a}\mathbb{E}i_S$,

$$\xi_S = \Lambda_{S,a}/\Lambda_{0,a} = |S|\mathbb{E}i_S/\mathbb{E}n_S. \quad (7)$$

For example, for $S = S_m$, a block of $m \times m$ pixels, this gives the following approximation of ξ_{S_m} :

$$\xi_{S_m} = m^2\mathbb{E}i_{S_m}/\mathbb{E}n_{S_m}. \quad (8)$$

As an illustration, Figure 2 shows a simulated rectangular footprint and its intersection with a block of 10×10 pixels.

The assumptions made on the footprints are intended to keep the model as simple as possible while capturing several important aspects. The size of \mathcal{F} is fixed. A random size should not make much difference in outcome: the mean number of pixels $\mathbb{E}n_S/\mathbb{E}i_S$ of S covered by a footprint hitting S , and therefore the ratio $\Lambda_{S,a}/\Lambda_{0,a}$ (see (8)), is primarily controlled by the mean size of \mathcal{F} (keeping the shape fixed). Furthermore, in view of the observed variation in shape of features in Figure 1, it may be argued that a random size would not improve the model without also allowing for a randomly varying shape.




Figure 2: A block of 10×10 pixels with a simulated rectangular footprint and their intersection.

For the choice of the shape, the streaks seen in Figure 1 suggest that anisotropy may be relevant. If f is a square, then ξ_{S_m} (see (8)) increases approximately quadratically in m for large m . However, if f is a rectangle which is much longer than its width, then eventually ξ_{S_m} increases approximately linearly in m . A rectangle is a simple shape for which both size and anisotropy can be varied, so it was adopted as model for f ; its length and width depend on duration. Such a simple model can of course not represent real footprints of downpours as observed in Figure 1, but it may be good enough to approximate the ECF.

Figure 1 gives the impression that the orientation of streaks is not uniformly distributed. This can be expected, as it should be related to the wind direction. On the other hand, the predominant orientation seems to vary from year to year, so even the 11 yr of radar data may not be representative for the long-term statistics of the orientation. Furthermore, simulations indicate that for domains S without a distinct orientation (such as the pixels covering squares and highway networks discussed in the next sections), predictions by the model (6) are insensitive to the distribution of θ . Therefore, the distribution of θ was taken as uniform.

4. Estimation from radar data

Let $\mathbb{1}_A$ be the indicator function of a set A : $\mathbb{1}_A(x) = 1$ if $x \in A$ and $\mathbb{1}_A(x) = 0$ otherwise. For a given set of pixels S covered completely by the weather radar data, and a given precipitation depth a , we can compute $\mathbb{1}_{(-\infty, a]}(p_S(\Delta))$. This is a very crude, but unbiased estimator of $\mathbb{P}(p_S(\Delta) \leq a)$ taking only the values 0 and 1. Due to homogeneity, the estimator can be refined by computing it for all translations $S + x$ of S within the area covered by the radar data and for all Δ -year periods for which data are present, and then averaging the values thus obtained. In the model (6), precipitation footprints have no preferred orientation, so translations of S rotated over $\pi/2$, π and $3\pi/2$ are also included to boost the

effective sample size. Due to partial overlap and spatial dependence, the values of $\mathbb{1}_{(-\infty, a]}(p_{S+x}(\Delta + t))$ for different x and t are dependent, but the estimator is unbiased.

$\mathbb{P}(p_0(\Delta) \leq a)$ is estimated similarly, but only from those pixels which are part of a translated copy $S + x$ of S (or one of its rotations) within the area covered by the radar data. This is to ensure that the estimates of $\mathbb{P}(p_S(\Delta) \leq a)$ and of $\mathbb{P}(p_0(\Delta) \leq a)$ are based on the same radar data. Subsequently, an estimate $\hat{\xi}_{S,a}$ of ξ_S is computed by substituting $\mathbb{P}(p_0(\Delta) \leq a)$ and $\mathbb{P}(p_S(\Delta) \leq a)$ in (4) by their estimates.

Note that the bias in the spatially and temporally averaged distribution of the radar precipitation data is immaterial: ξ_S itself does not depend on a ; furthermore, $\hat{\xi}_{S,a}$ only depends on the relationship between $\mathbb{P}(p_S(\Delta) \leq a)$ and $\mathbb{P}(p_0(\Delta) \leq a)$, so only the label a can be wrong. By presenting $\hat{\xi}_{S,a}$ as a function of $\mathbb{P}(p_0(\Delta) \leq a)$ instead of as a function of a , it becomes invariant to bias in the averaged distribution of the radar precipitation. Local/instantaneous deviations from the nominal relation between precipitation and radar-derived precipitation may affect the estimates of ξ_S , but their net contribution should be small as long as these deviations are reasonably smooth in space and time.

In principle, this estimator can be applied directly to every set of radar pixels S . However, if the extent of S is large, only few rotations and translations are fully covered by the radar data, so $\hat{\xi}_{S,a}$ is inaccurate. Then it becomes attractive to use a model to simulate (4): the radar data are only needed to estimate the model parameters. Estimates of the values of ξ for a limited collection of test sets should be enough for this purpose. An example of such a collection is the set of all pairs of pixels (x, y) . That choice produces estimates of the bivariate statistic (5). However, as argued in Section 3, bivariate statistics only reflect dependence between two local temporal maxima, which tells little about the statistics of spatiotemporal maxima of precipitation (see Section 1).

In the present study, blocks of $m \times m$ pixels S_m , with m ranging from 1 to some maximal value M , are used as test sets. The values of ξ_{S_m} for different m reflect the effect of domain size, but footprint anisotropy should also be detectable from these values (see Section 3). Δ is fixed to 1 yr. Examples of estimates $\hat{\xi}_{S_m,a}$ as functions of m for several values of $\mathbb{P}(p_0(1) \leq a)$ are shown as thick lines in Figure 3. Simulations (thin dots) using square footprints of width ranging from 1 to 15 pixels have slightly stronger curvature (because of the fixed vertical scale, this is most readily seen for a duration of 15 min). This indicates some anisotropy, but also suggests that anisotropy may be difficult to estimate from the estimates of ξ for this collection of test sets.

For each duration, the footprint width w and length l are determined from the estimates $\hat{\xi}_{S_m,a}$ of ξ_{S_m} and simulations $\xi_{S_m}(w, l)$ of ξ_{S_m} using (6) with f a $w \times l$




Figure 3: ECF estimates $\hat{\xi}_{S_m}$ versus block length m in units of 900 m for precipitation depths a with $\mathbb{P}(p_0(1) \leq a)$ equal to 0.9 (thick dashes), 0.95 (thick full) and 0.98 (thick dotted), for three durations. The thin dotted curves are ξ_{S_m} simulated using square footprints of various sizes.

rectangle, by minimising

$$\sum_{m \in \{1, \dots, M\}} |\xi_{S_m}(w, l) - \hat{\xi}_{S_m, a}|^2 m^{-2} \quad (9)$$

over suitable ranges for w and l . The minimization is performed over discrete values of width $w \in \{1, 1.5, 2, \dots, 15\}$ and length $l \in \{1, 2, 3, \dots, 40\}$ in units of pixel size (900 m), with $l \geq w$. The quadratic penalty on the mismatch between $\xi_{S_m}(w, l)$ and $\hat{\xi}_{S_m, a}$ in (9) is reasonable if the effective sample size is large enough that errors in $\hat{\xi}_{S_m, a}$ are approximately normal (this depends on a). The factor m^{-2} accounts for the increase in variance of $\hat{\xi}_{S_m, a}$ due to the increasing overlap between translated copies of S_m with increasing m . The maximal block size M is 15: at larger values of m , few translated blocks S_m are found which have valid radar data in each of its pixels.

The parameters w and l were estimated for durations from 15 min to 12 h and for a corresponding to $\mathbb{P}(p_0(1) \leq a) = p$ with $p \in \{0.901, 0.902, \dots, 0.999\}$ (local return periods above about 10 yr). The results are depicted in Figure 4. The estimates of width and length are fairly stable as functions of p up to about 0.98. They tend to increase with duration; in particular the width.

Figure 5 shows the medians of the estimates for p between 0.94 and 0.96 versus duration τ , together with the fitted relationships

$$w = 1.06\tau^{0.255}, \quad l = 10.2\tau^{0.128}, \quad (10)$$

obtained by linear regression of the logarithms of w and l against the logarithm of τ . The curves match the estimates well.

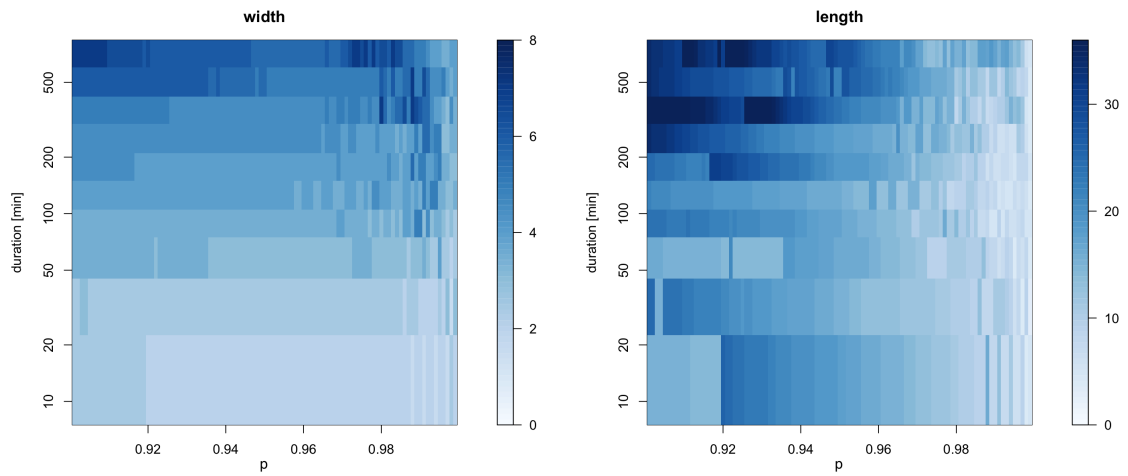


Figure 4: Estimates of footprint width and length in units of pixel width (900 m) derived from estimates of the ECF for a precipitation depth a , as functions of $p = \mathbb{P}(p_0(1) \leq a)$ and duration (min).




Figure 5: Estimates of footprint width (triangle) and length (circle) in units of pixel width (900 m) as functions of duration (min), with their regression lines (full) and the pointwise 95% confidence intervals for this regression lines (dashed). See text for details.

The figure contains estimates of pointwise 95% confidence intervals (or compatibility intervals [35]), which express the sampling variability in the estimates in the form of a range of values compatible with the data. They are estimated by a block bootstrap [36]. Assuming that the dependence between precipitation maxima in different years is weak, the block length is set at one year. The bootstrap sample size is 50; a much larger sample would require a prohibitive computational effort. To increase reliability with such a small sample size, the bootstrap is only used to estimate the variances of the logarithms of width and length; a normal approximation is used to compute the confidence intervals. The nonparametric bootstrap (and therefore, the block bootstrap) is crude [37], in particular as bootstrap samples are drawn from only 11 elements (the 1-yr blocks). But it is sophisticated in the way it accounts for all dependencies present in the data and resulting from the estimation procedure, up to the computation of the regression curves in Figure 10.

The estimates of width in this figure are very precise, but the estimates of length are not. The underlying reason is that the overall level of the curve of $\xi_{S,m}$ as function of m is most sensitive to the smallest of the two length scales. Each of the two curves in Figure 10 is far from the confidence intervals of the other curve; this indicates that the anisotropy of the footprint can indeed be estimated.

5. Verification on radar data covering highway networks

The model of random strip-like precipitation footprints can be applied immediately to any set of pixels S to estimate ξ_S , and to compute the frequency of exceedance $\Lambda_{S,a}$ of a high precipitation depth a somewhere in S from its frequency of exceedance $\Lambda_{0,a}$ for a single pixel.

An intended application of the present study is to estimate the frequency that precipitation depth accumulated in a given duration exceeds a given large value a somewhere on a given part of the highway network of the Netherlands. To apply the radar data to this problem, the spatial resolution of the highway network needs to be brought in line with the radar data; therefore, it is approximated by the set of pixels intersecting it (see Section 6 for a discussion). For model checking, subsets S of these pixels within squares of 35×35 pixels² are selected. An example is displayed in Figure 6.

The probabilities $\mathbb{P}(p_S(1) \leq a)$ and $\mathbb{P}(p_0(1) \leq a)$ for this S are estimated directly from the radar data using the estimator described at the start of Section 4. These probability estimates are converted to return periods: $T_{S,a} = -1/\log(\mathbb{P}(p_S(1) \leq a))$ for S , and $T_{0,a} = -1/\log(\mathbb{P}(p_0(1) \leq a))$ for a single pixel, which follows from (2) and (3).

In Figure 7, the graph of $T_{S,a}$ versus $T_{0,a}$ (with a varying over the upper 10% of the radar precipitation data) is plotted on a double-logarithmic scale for every duration, with its pointwise 95% confidence intervals estimated by the block




Figure 6: 194 pixels covering part of the highway network of the Netherlands: case I.

bootstrap (see Section 4). Each plot also shows the relationship predicted by the model of Section 4:

$$T_{S,a}/T_{0,a} = \Lambda_{0,a}/\Lambda_{S,a} = 1/\xi_S, \quad (11)$$

using the ECF ξ_S predicted with the parameter estimates in (10).

Some bias in the relationships predicted by the model appears to be present, as they are outside the confidence intervals for certain return periods and durations. One should keep in mind, however, that these bootstrap confidence intervals are crude, and tend to be too narrow rather than too wide (e.g. by about 10% for the mean of a normal random sample of size 11). Therefore, it is fair to say that the results indicate bias, but not more than that.

Figures 8-11 show selected estimates for four more sets of pixels covering highway networks of varying density and size. For the first two of these, the results are similar to those in Figure 7, even though the highway networks have widely different shapes. The highway networks in the successive Figures 9-11 decrease in size, resulting in increasing return periods $T_{S,a}$. For the first two of these, similar bias patterns are observed, but for the last one (a straight section covered by only 21 pixels), bias appears to be reduced considerably, conform expectation.

The most notable difference between the predicted curves and the direct estimates from radar precipitation data is that the former have consistently larger slopes than the latter. The slopes of the estimated curves are robust to noise in the data: this was assessed by repeating the analysis on maps of annual maximum precipitation perturbed by multiplicative noise of varying intensity. Because of the logarithmic scales in these plots, the slopes for the predictions must equal 1: according to (11), $\log T_{S,a} - \log T_{0,a} = -\log \xi_S$, a constant. In fact, this must hold

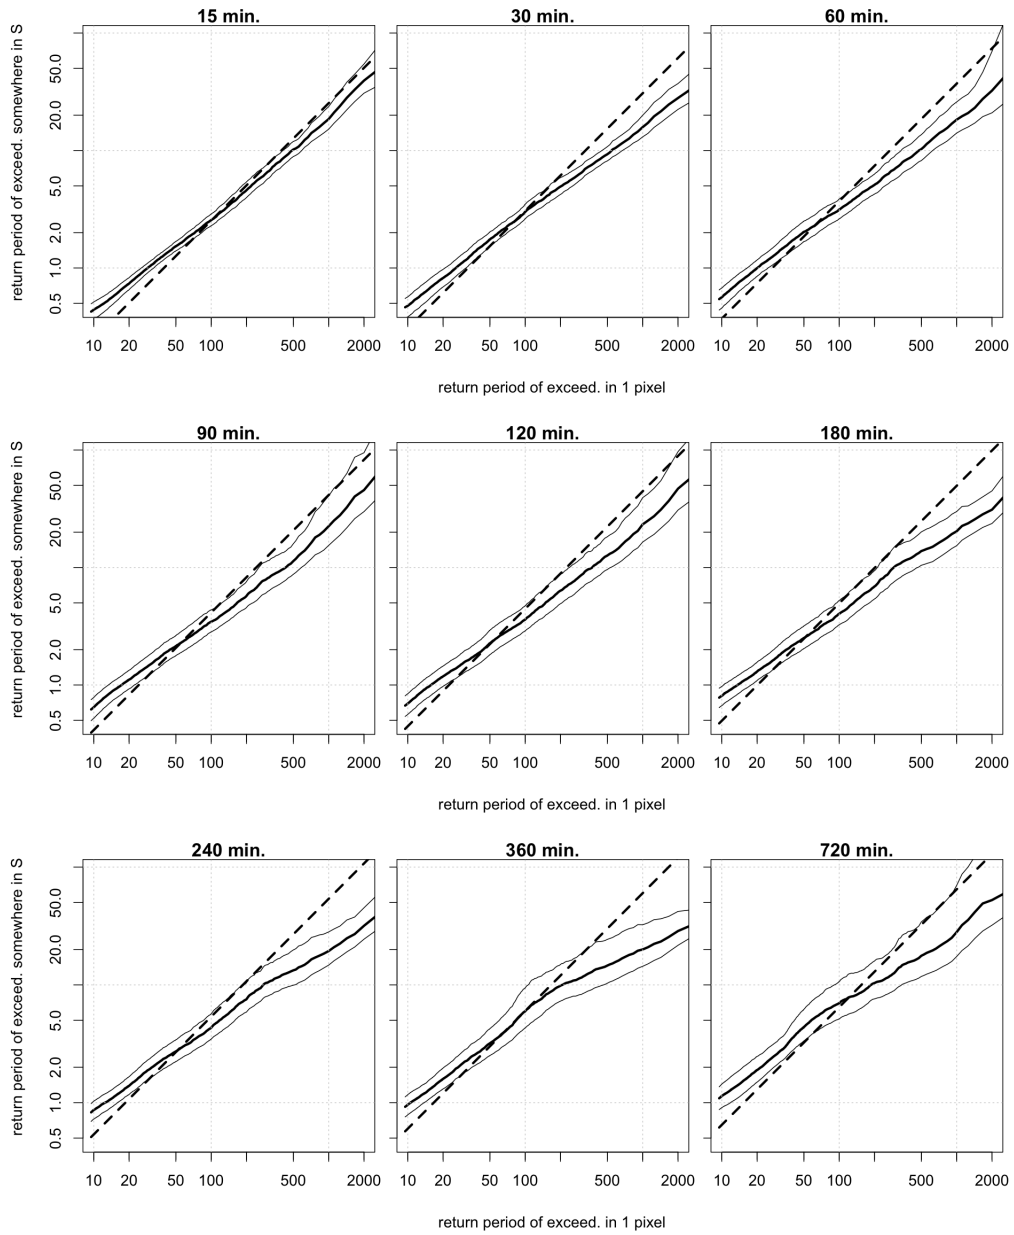


Figure 7: Relationship between the return period of exceedance in 1 pixel of a precipitation depth (horizontal) and the return period of exceedance at some pixel in S of the same depth (vertical), estimated directly from radar data (full) with 95% confidence intervals (dotted), and predicted by the model (dashed), for case I and durations from 15 min to 12 h.




Figure 8: Case II: 168 pixels covering the highway network (top), and return periods of exceedance at some pixel in S and at 1 pixel (bottom; see Figure 7 for explanation).




Figure 9: Case III: 213 pixels covering the highway network (top), and return periods of exceedance at some pixel in S and at 1 pixel (bottom; see Figure 7 for explanation).

for all models with a max-stable dependence structure: these models only differ in the values of $-\log \xi_S$ for various sets S , which correspond to vertical shifts of the predictions in Figures 7-11. Given this restriction on the slope, it appears that the model of Section 4 is about as good as can be expected from any model with a max-stable dependence structure, no matter how sophisticated: all we can do with such a model is change the return period where the predicted and measured curves intersect. The apparent bias can only be reduced substantially by somehow reducing the slopes of the predicted curves in this plots.

Since the vertical position of a predicted curve (straight line with unit slope) increases with increasing footprint, the empirical curves, in particular those for durations upwards from 180 min, indicate that in the upper range of return periods, smaller footprints prevail than in the lower range. This suggests an association of the former with larger-scale (possibly stratiform) precipitation and of the latter with more localized convective precipitation.




Figure 10: Case IV: 77 pixels covering the highway network (top), and return periods of exceedance at some pixel in S and at 1 pixel (bottom; see Figure 7 for explanation).




Figure 11: Case V: 21 pixels covering the highway network (top), and return periods of exceedance at some pixel in S and at 1 pixel (bottom; see Figure 7 for explanation).

6. Approximation of the statistics of extreme precipitation on highway networks

Resolution issues. In the model of Section 3, S is a set of discrete radar pixels of 900 m width. To approximate the statistics of extreme precipitation over a highway network, S is taken as the set of pixels intersecting with the network. However, a somewhat higher spatial resolution of say 100 m would seem more appropriate for this purpose. In principle, the key relationship (4) presented in Section 3 can also be formulated for average precipitation depths over square cells of the desired resolution ε , yielding the approximation

$$\Lambda_{S^\varepsilon, a}^\varepsilon = \Lambda_{0, a}^\varepsilon \xi_{S^\varepsilon}^\varepsilon, \quad (12)$$

with S^ε the cells of width ε intersecting with the highway network, ξ^ε the analog of ξ at the resolution ε , and $\Lambda_{S^\varepsilon, a}^\varepsilon$ the frequency of a precipitation depth larger than a accumulating on some cell of S^ε .

We do not have access to estimates of any of these variables, so they need to be approximated by variables we can estimate. S^ε is approximated on the resolution of the radar pixels by S , and $\xi_{S^\varepsilon}^\varepsilon$ is approximated by ξ_S , estimated from radar data (Section 4). Disregarding all sources of error except (effective) resolution, $\xi_{S^\varepsilon}^\varepsilon$ is underestimated by ξ_S .

$\Lambda_{0, a}^\varepsilon$ is the frequency that average precipitation depth over a cell of resolution ε exceeds a . It could be approximated by an estimate of $\Lambda_{0, a}$ derived from the radar precipitation data. However, such an estimate is likely less reliable than an estimate from rain gauge data, due to various issues with the retrieval of precipitation from radar backscatter [19, 38, 39, 40]. Moreover, for large a , $\Lambda_{0, a}^\varepsilon$ is in principle underestimated by $\Lambda_{0, a}$. For these reasons, $\Lambda_{0, a}^\varepsilon$ is approximated by the frequency $\Lambda_{0, a}^0$ that precipitation depth exceeds a in a point, derived from a DDF relation estimated from rain gauge measurements. Due to variability on scales between the cross-section of a rain gauge and ε , the approximation tends to overestimate $\Lambda_{0, a}^\varepsilon$ for large a .

For our approximation $\Lambda_{S^\varepsilon, a}^\varepsilon \approx \Lambda_{0, a}^0 \xi_S$ of (12), the net effect of underestimation of $\xi_{S^\varepsilon}^\varepsilon$ by ξ_S and overestimation of $\Lambda_{0, a}^\varepsilon$ by $\Lambda_{0, a}^0$ is difficult to assess. Experimental data and modelling of small-scale variability of precipitation [41, 42] may provide more insight. In particular data from very high resolution weather radar systems such as IDRA [43] seem promising for bridging the gap between the scales of a road and a pixel of a standard weather radar system.

DDF relation. Conventionally, an extreme value distribution (also known as max-stable or GEV distribution) [22, 21]

$$F_{GEV}(a) = e^{-(1+\gamma\frac{a-\omega}{\sigma})^{-1/\gamma}} \quad (13)$$

with parameters (γ, σ, ω) is used as model for the distribution function of the annual maxima of precipitation of given duration for a single site (i.e., rain gauge); examples for the Netherlands are [44, 19] and part 3 of [29]. The parameter γ is known as the extreme value index [21]; in hydrology, the GEV (13) is also expressed in terms of $\kappa = 1/\gamma$. If (13) holds for annual maxima, then the statistics of maxima over epochs longer than one year are given by a GEV with the same value of γ , but with different values of the the scale σ and the location ω . A max-stable process (Section 1) is at every point distributed as in (13). For the frequency $\Lambda_{0,a}^0$ that precipitation depth exceeds a in a point, (13) gives $\Lambda_{0,a}^0 = (1 + \gamma(a - \omega)/\sigma)^{-1/\gamma}$.

A recent estimate of the DDF relation for the Netherlands from automatic registrations of precipitation at nominally 31 rain gauges is reported in part 1 of [29], partly based on [45]. In [45], GEV fits computed for various durations on 446 annual maxima of precipitation recorded at nominally 31 rain gauges over 2003-2016 are compared to fits of the generalised logistic distribution (GLO)

$$F_{GLO}(a) = \left(1 + (1 + \gamma' \frac{a - \omega'}{\sigma'})^{-1/\gamma'}\right)^{-1}. \quad (14)$$

This is not an extreme value distribution; its suitability for precipitation extremes was examined in e.g. [46, 47, 48]. [45] find that for short durations, GLO fits match the empirical distributions of the highest 10 annual maxima better than GEV, although the GEV distribution is not incompatible with the data according to the Anderson-Darling test.

For highway design and maintenance in the Netherlands, an important number is the frequency that somewhere on a given highway network, the 10-yr precipitation depth for a single point (rain gauge) is exceeded. It is estimated by $0.1\xi_S$. The latter depth (the value a such that $\Lambda_{0,a}^0 = 0.1$) is estimated accurately from rain gauge data [29] and given this a , its estimated return period of 10 yr is accurate as well.

Specifically for (sets of) tunnels and lowered highway sections, the focus is on the frequency that somewhere, the 250-yr precipitation depth for a single site is exceeded. The estimate of this depth value (and given the value, its return period) may suffer from bias; [45] shows appreciable differences in estimated DDF relations based on different distribution functions (see below). To estimate the precipitation depth accumulating in 10 min once per 10 yr somewhere on the highway network covered by the pixels in Figure 6, the precipitation depth for a return period of 442 yr needs to be obtained from the DDF relation. This increases to more than 10,000 yr for the complete highway network of the Netherlands (3750 km, total area 90 km², covered by pixels of total area 3481 km² = 9% of land area). In such cases, bias in the extrapolation of the estimated DDF relation may become a critical issue.

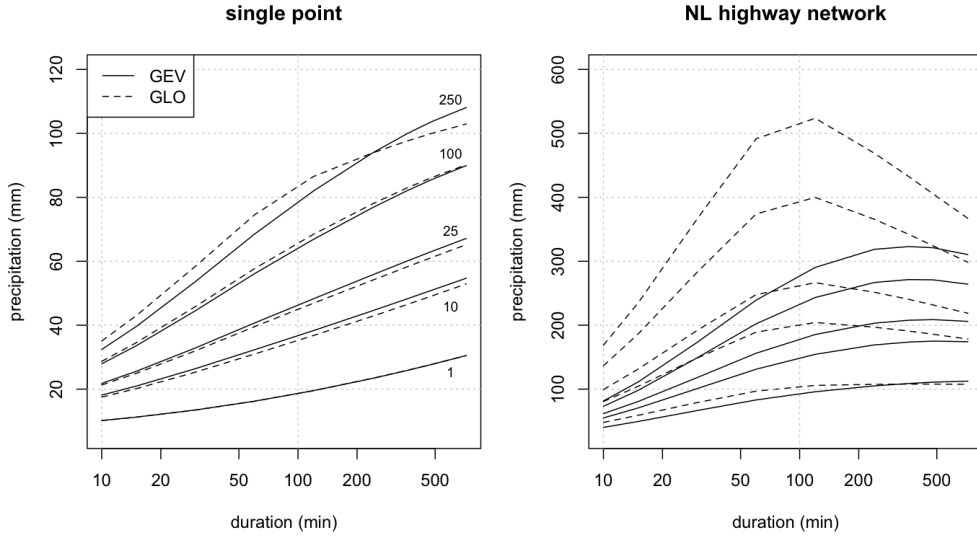


Figure 12: Crude estimates (without monotonicity imposed) of precipitation exceeded once per 1, 10, 25, 100 and 250 yr at a single site (left) and somewhere on the highway network of the Netherlands (right) as functions of duration, based on GEV (full) and GLO (dashed) distributions from and derived from [29] (see text).

Figure 12 (left) shows DDF curves based on GLO (full) and GEV (dashed) fits. Their parameters are smooth functions of duration from part 1 of [29], except the GEV dispersion coefficient σ/ω , which was extended to durations below 120 min by matching the GEV curves to the GLO curves over return periods of 1-150 yr. The two distribution functions give similar estimates for return periods up to about 100 yr. The panel on the right shows the corresponding precipitation depths exceeded somewhere on the highway network of the Netherlands with given return periods, derived using the model of Section 4. For GEV, departures from monotonicity are small and occur only for return periods upwards from 10 yr and durations upwards from 6 h. In contrast, for return periods above 2 yr, the GLO estimates peak at a duration of 2 h and are very high: the 100-yr precipitation over 2 h is 400 mm. For comparison, the global record of precipitation measured within 1 h is reported to be 401 mm in Shangdi, Nei Monggol, China on July 3, 1975 [49, Table II.5.6]; on average, this would be exceeded once per 125 yr on the Dutch highways. An example in a more similar climate is the exceptional downpour of 220 mm in 2 hours recorded on July 28, 2014 in the German city of Münster; this would be almost a decadal event on the Dutch highways. These numbers do not seem plausible. We may therefore conclude that even though GLO may match available data more closely than GEV, its extrapolation to large return periods and (as a consequence) its estimates of return values of precipitation maxima over large spatial domains are less reliable. For this reason, the DDF relation based

on GEV has been selected. It is difficult to assess how much bias is present in the GEV-based DDF relation for very high return periods. This might be checked by comparing the GEV estimates to estimates based on plausible alternative tail models [50, 51] or based on more refined models accounting for relevant covariates.

Error analysis. For the complete model, the following types of errors can be distinguished:

- a. bias in the ECF due to limited spatial resolution, and the local/instantaneous component of bias in radar precipitation (this section and Section 4);
- b. bias in the ECF due to model formulation and estimation (Section 5);
- c. bias in the DDF relation (this section);
- d. sampling error (the combined effect of sampling error in the ECF (Section 4) and in DDF estimates).

To estimate the statistics of the sampling error in estimates of return periods (of given precipitation depths) or return values (for given return periods), a "parametric bootstrap" [52, 53, 37] is used: 250 random samples of 446 independent annual maxima are drawn, based on the GEV-based DDF relation (see above), and for each sample,

- the GEV parameters are estimated by the maximum likelihood method,
- a random value of the estimate $\hat{\xi}_S$ of ξ_S is drawn, assuming that its logarithm is normally distributed with mean derived earlier from the model of Section 4 with the parameters in (10), and variance derived from the nonparametric bootstrap sample of these parameters (see Section 4),
- the desired model outputs (return periods and return values for the maximum of precipitation within the set S) are computed using the results of the two previous steps.

From the ensemble of simulated of model outputs, confidence intervals of model outputs are estimated using normal approximations of the distribution functions of the logarithms of return period and return value estimates.

This procedure accounts for sampling error in the estimate of the DDF relation as well as sampling error in the estimate of the spatial model of Section 4. By comparing the outcomes computed with only one error source, we can see which one contributes more to the sampling error in a model outcome. In most cases of practical interest, the sampling error in the estimate of the DDF relation exceeds the sampling error in the estimate of the spatial model. For example, for Case I in Figure 6, the former predominates for return values of the maximum precipitation over de set S for all return periods from 0.5 to 250 yr and durations from 10 to 720

min. For the return period of exceedance somewhere on S of the T -yr precipitation depth for a single site, the sampling error in the estimate of the DDF relation predominates for all T above 5 yr. $T \geq 10$ yr is relevant for highway design and maintenance in the Netherlands. For smaller S (e.g. the pixels covering a tunnel), the sampling error in the estimate of the DDF relation is even more predominant.

Case I	10 yr	25 yr	50 yr	100 yr	250 yr
30 min	-0.56/0.14	-0.34/0.21	-0.19/0.28	-0.01/0.36	+0.11/0.50
120 min	-0.44/0.14	-0.20/0.21	-0.02/0.27	+0.21/0.35	+0.40/0.47
720 min	-0.46/0.16	-0.23/0.22	-0.20/0.29	+0.03/0.36	+0.46/0.48
Case V	10 yr	25 yr	50 yr	100 yr	250 yr
30 min	-0.32/0.13	-0.21/0.20	-0.10/0.27	+0.00/0.36	+0.06/0.50
120 min	-0.23/0.13	-0.11/0.20	+0.01/0.27	+0.12/0.35	+0.24/0.47
720 min	-0.29/0.13	-0.12/0.20	-0.09/0.27	+0.08/0.35	+0.37/0.48

Table 1: Comparison of apparent bias to sampling error of predicted return periods: ratio of $\log(T_{S,a}/\hat{T}_{S,a})$ (numerator) to $\sigma(\log T_{S,a})$ (denominator), with $T_{S,a}$ the predicted return period of exceedance of a somewhere in S , $\hat{T}_{S,a}$ the same return period estimated from the radar data, and $\sigma(\log T_{S,a})$ the estimate of the standard deviation of $\log T_{S,a}$, for several values of duration and return period $T_{0,a}$ of a for a site. Top: case I (Figure 6); bottom: case V (Figure 11).

For case I in Figure 6, Table 1 shows a crude indicator of the ratio of bias to the standard deviation of the predicted return period $T_{S,a}$ of exceedance somewhere on S of the precipitation depth a . The depth a is indicated by its return period of exceedance $T_{0,a}$ for a single site. The indicator is a ratio of relative errors, but this is immaterial in this case, as the normalisation is the same in numerator and denominator. Other sources of bias (labelled a. and c. in the list) are not considered, as not enough is known about these yet. The standard deviation $\sigma(\log T_{S,a})$ accounts for all sampling error and is assessed by the parametric bootstrap above. For $T_{0,a}$ of 50 yr and higher (extreme precipitation), bias appears to be smaller than standard deviation, so the 95% confidence intervals for the model predictions give a reasonable indication of the total error, including bias. For $T_{0,a} = 10$ yr, bias exceeds the low standard deviation in magnitude, so the confidence intervals are not of much use. However, even in this range, the apparent bias in return periods is not larger than about 50%. Furthermore, the model is seen to underestimate return periods (hence overestimate frequencies of exceedance) in this range. For comparison, results for a much smaller stretch of highway (case V) covered by the pixels in Figure 11 are shown. The ratios of bias to standard deviation are smaller in this case, but the pattern is similar. Note that the standard deviations of the direct estimates $\hat{T}_{S,a}$ of return periods from the radar data are much larger than the standard deviations of the predictions $T_{S,a}$, so the numerators in Table 1 are

at best indicative.

7. Discussion

A concrete result of the present study is a simple max-stable model for predicting spatiotemporal extremes of precipitation. It consists of two building blocks: the duration-dependent extremal coefficient function (ECF) ξ , representing the spatial dependence of extreme precipitation, and the depth-duration-frequency (DDF) relation representing the frequencies of exceedance of large values of precipitation for a single site.

The new insights from this study have mainly come from

- i. estimation of the ECF for various spatial sets, using a range of thresholds. Usage of the ECF in empirical studies has so far been limited to the bivariate statistic (i.e., the ECF for pairs of sites),
- ii. high resolution weather radar data, used to estimate the ECF and to calibrate a model by matching predictions to ECF estimates for selected test sets.

The model is deliberately kept as simple as possible in order to find out which aspects matter most for predicting the ECF for sets of radar pixels covering highway networks. For footprints of heavy precipitation schematized to rectangles of fixed length and width, the width (the smallest of the two length scales) is key; anisotropy matters, but has a smaller impact on predictions and is more difficult to estimate. An important insight from Section 5 is that despite the simplicity of the model, it is hard to improve its predictions by a more sophisticated max-stable model: any such model predicts straight lines of unit slope for the return period that a precipitation depth is exceeded somewhere on a set of pixels S as a function of its return period of exceedance in a single pixel, but the empirical curves in Figures 7-11 have lower slopes.

To lower the predicted slopes, the predicted footprint sizes should decrease somewhat with return period. A simple but physically plausible way to achieve this is to model the data as resulting from a mixture of two types of heavy precipitation events, each class modelled by a max-stable model with its own ECF and DDF relation, for example of the same form as the model considered in this study. One type has larger footprints and its annual maxima have distribution functions with lighter tails, the other type has smaller footprints and heavier tails. The shapes of the empirical curves in Figures 7-11 for durations upward from 180 min indeed suggest that two distinct scales are present, each predominant in a different range of return periods. The event types may be defined and separated based on covariates like season, dew point temperature, or observed cloud type [54]. In [45], the empirical distributions of annual maxima of hourly precipitation corresponding to dew point temperatures below and above 17.5°C appear to be matched well by

GEV fits with different shape parameters. The morphology of features in the radar precipitation maps may also be useful, as well as tracking data of individual events derived from weather radar data [16].

For the current model, the radar data contribute only a minor part of the sampling error in predictions (see Section 6), so a more refined model of the spatial dependence of extremes (having a larger number of parameters) may be estimated without substantially increasing the sampling error.

However, for estimating the statistics of precipitation maxima over highway networks, even the simple model from this study appears to be fit for this purpose. Table 1 indicates that for a typical highway network S , bias exceeds sampling error only for precipitation depths a with return periods for a site of up to 25 yr, and that the model overestimates frequencies of exceedance of a on S in this range by not more than about 50% (this is not large; note further that bias is much smaller when expressed in terms of precipitation depth). Hence, provided that the magnitude of bias is captured by these estimates, the model is suitable for mitigating risk.

To assess future risk to the highway infrastructure posed by extreme precipitation, adaptations of the DDF relation to several different climate scenarios for the Netherlands from Part II of [29] can be used in the model. It is assumed that the spatial coherence of heavy precipitation (i.e., the ECF) remains the same. [16, 17] indicates that the sizes of spatial footprints of heavy precipitation will increase, implying that the present model may be overcautious in this respect.

Another purpose for which the model may be applied is risk communication: in particular, for explaining why the highest precipitation depth measured in some region or country can be (much) higher than the one for an arbitrary single site for the same return period.

Considering the fine features in the maps in Figure 1 and the footprint dimensions estimated from such data, it seems plausible that statistics of bivariate dependence derived from rain gauge data give the impression of asymptotic independence of precipitation maxima at different sites, as was found in many studies (see Section 1). It would be interesting to see whether a max-stable model of localized events such as the model from this study can indeed be reconciled with these statistics, by comparing them to the same statistics obtained from simulations by such a model.

8. Acknowledgements

The authors would like to thank Irene Garcia Marti for her help in data processing, and Paul Fortuin, Ruthger Smit and Ivonne van Pelt for their guidance and feedback.

References

- [1] C. Braak, *Het klimaat van Nederland A*, KNMI Mededelingen en Verhandelingen 34a (1933).
- [2] D. Yarnell, *Rainfall intensity-frequency data*, 204, US Government Printing Office, 1935.
- [3] K. van Muiswinkel, P. Fortuin, Working towards climate resilient highway infrastructure in The Netherlands, in: *First International Conference on Surface Transportation System Resilience to Climate Change and Extreme Weather Events*, Transportation Research Circular, volume E-C204, Transportation Research Board, 2015, p. 22.
- [4] T. Buishand, Bivariate extreme-value data and the station-year method, *Journal of Hydrology* 69 (1984) 77–95.
- [5] S. G. Coles, J. A. Tawn, Modelling extremes of the areal rainfall process, *Journal of the Royal Statistical Society: Series B (Methodological)* 58 (1996) 329–347.
- [6] T. Buishand, L. De Haan, C. Zhou, On spatial extremes: with application to a rainfall problem, *The Annals of Applied Statistics* 2 (2008) 624–642.
- [7] A. C. Davison, S. A. Padoan, M. Ribatet, Statistical modeling of spatial extremes, *Statistical science* 27 (2012) 161–186.
- [8] A. C. Davison, R. Huser, E. Thibaud, Geostatistics of dependent and asymptotically independent extremes, *Mathematical Geosciences* 45 (2013) 511–529.
- [9] E. Thibaud, R. Mutzner, A. Davison, Threshold modeling of extreme spatial rainfall, *Water Resources Research* 49 (2013) 4633–4644.
- [10] F. Serinaldi, A. Bárdossy, C. G. Kilsby, Upper tail dependence in rainfall extremes: would we know it if we saw it?, *Stochastic environmental research and risk assessment* 29 (2015) 1211–1233.
- [11] A. Stephenson, E. Lehmann, A. Phatak, A max-stable process model for rainfall extremes at different accumulation durations, *Weather and climate extremes* 13 (2016) 44–53.
- [12] J. Blanchet, J.-D. Creutin, Co-occurrence of extreme daily rainfall in the French Mediterranean region, *Water Resources Research* 53 (2017) 9330–9349.

- [13] C. Rupa Rajulapati, P. P. Mujumdar, Dependence structure of urban precipitation extremes, *Advances in Water Resources* 121 (2018) 206–218.
- [14] P. D. Le, A. C. Davison, S. Engelke, M. Leonard, S. Westra, Dependence properties of spatial rainfall extremes and areal reduction factors, *Journal of Hydrology* 565 (2018) 711–719.
- [15] K. Saunders, A. Stephenson, D. Karoly, A regionalisation approach for rainfall based on extremal dependence, *Extremes* (2020) 1–26.
- [16] K. Lochbihler, G. Lenderink, A. P. Siebesma, The spatial extent of rainfall events and its relation to precipitation scaling, *Geophysical Research Letters* 44 (2017) 8629–8636.
- [17] K. Lochbihler, G. Lenderink, A. P. Siebesma, Response of extreme precipitating cell structures to atmospheric warming, *Journal of Geophysical Research: Atmospheres* 124 (2019) 6904–6918.
- [18] A. Overeem, I. Holleman, A. Buishand, Derivation of a 10-year radar-based climatology of rainfall, *Journal of Applied Meteorology and Climatology* 48 (2009) 1448–1463.
- [19] A. Overeem, T. Buishand, I. Holleman, Extreme rainfall analysis and estimation of depth-duration-frequency curves using weather radar, *Water Resources Research* 45 (2009).
- [20] L. De Haan, A spectral representation for max-stable processes, *The annals of probability* 12 (1984) 1194–1204.
- [21] L. de Haan, A. Ferreira, *Extreme value theory - An Introduction*, Springer-Verlag, New York, 2006.
- [22] R. Fisher, L. Tippett, On the estimation of the frequency distributions of the largest or smallest member of a sample, *Proceedings of the Cambridge Philosophical Society* 24 (1928) 180–190.
- [23] K. Strokorb, M. Schlather, An exceptional max-stable process fully parameterized by its extremal coefficients, *Bernoulli* 21 (2015) 276–302.
- [24] J. Wadsworth, J. Tawn, Dependence modelling for spatial extremes, *Biometrika* 99 (2012) 253–272.
- [25] M. A. Ancona-Navarrete, J. A. Tawn, Diagnostics for pairwise extremal dependence in spatial processes, *Extremes* 5 (2002) 271–285.

- [26] A. Overeem, T. Buishand, I. Holleman, R. Uijlenhoet, Extreme value modeling of areal rainfall from weather radar, *Water Resources Research* 46 (2010).
- [27] A. Overeem, H. Leijnse, R. Uijlenhoet, Measuring urban rainfall using microwave links from commercial cellular communication networks, *Water. Resour. Res.* 47 (2011) n/a–n/a. W12505.
- [28] F. Fabry, *Radar meteorology: principles and practice*, Cambridge University Press, 2015.
- [29] J. Beersma, H. Hakvoort, R. Jilderda, A. Overeem, R. Versteeg, *Neerslagstatistiek en reeksen voor het waterbeheer 2019*, STOWA, Amersfoort, 2019.
- [30] D. J. Daley, D. Vere-Jones, *An Introduction to the Theory of Point Processes. Volume I: Elementary Theory and Methods*, Springer-Verlag, New York, 2003.
- [31] L. Le Cam, A stochastic description of precipitation, in: *Proceedings of the fourth Berkeley symposium on mathematical statistics and probability*, volume 3, University of California Press Berkeley, 1961, pp. 165–186.
- [32] M. R. Leadbetter, G. Lindgren, H. Rootzén, *Extremes and related properties of random sequences and processes*, Springer, 2012.
- [33] M. Schlather, J. Tawn, Inequalities for the extremal coefficients of multivariate extreme value distributions, *Extremes* 5 (2002) 87–102.
- [34] R. L. Smith, Max-stable processes and spatial extremes, Unpublished manuscript 205 (1990) 1–32.
- [35] V. Amrhein, S. Greenland, B. McShane, Scientists rise up against statistical significance (comment), *Nature* 567 (2019) 305–307.
- [36] H. R. Künsch, The jackknife and the bootstrap for general stationary observations, *Annals of Statistics* 17 (1989) 1217–1241.
- [37] J. Kysely, A cautionary note on the use of nonparametric bootstrap for estimating uncertainties in extreme-value models, *Journal of Applied Meteorology and Climatology* 47 (2008) 3236–3251.
- [38] H. Eldardiry, E. Habib, Y. Zhang, On the use of radar-based quantitative precipitation estimates for precipitation frequency analysis, *Journal of Hydrology* 531 (2015) 441–453.

- [39] F. Marra, E. Morin, Use of radar QPE for the derivation of intensity–duration–frequency curves in a range of climatic regimes, *Journal of hydrology* 531 (2015) 427–440.
- [40] E. Paixao, M. M. Q. Mirza, M. W. Shephard, H. Auld, J. Klaassen, G. Smith, An integrated approach for identifying homogeneous regions of extreme rainfall events and estimating IDF curves in Southern Ontario, Canada: Incorporating radar observations, *Journal of Hydrology* 528 (2015) 734–750.
- [41] W. F. Krajewski, G. J. Ciach, E. Habib, An analysis of small-scale rainfall variability in different climatic regimes, *Hydrological sciences journal* 48 (2003) 151–162.
- [42] N. Peleg, F. Marra, S. Fatichi, A. Paschalis, P. Molnar, P. Burlando, Spatial variability of extreme rainfall at radar subpixel scale, *Journal of Hydrology* 556 (2018) 922–933.
- [43] H. Leijnse, R. Uijlenhoet, C. Van De Beek, A. Overeem, T. Otto, C. Unal, Y. Dufournet, H. Russchenberg, J. Figueras i Ventura, H. Klein Baltink, et al., Precipitation measurement at CESAR, the Netherlands, *Journal of Hydrometeorology* 11 (2010) 1322–1329.
- [44] A. Overeem, T. Buishand, I. Holleman, Rainfall depth-duration-frequency curves and their uncertainties, *Journal of Hydrology* 348 (2008) 124–134.
- [45] J. Beersma, R. Versteeg, H. Hakvoort, Neerslagduur voor korte duren - Actualisatie 2018, STOWA, Amersfoort, 2018.
- [46] M. G. Schaefer, Regional analyses of precipitation annual maxima in Washington state, *Water Resources Research* 26 (1990) 119–131.
- [47] Y. Alila, A hierarchical approach for the regionalization of precipitation annual maxima in Canada, *Journal of Geophysical Research* 104 (1999) 31645–31655.
- [48] J. Kyselý, Regional growth curves and improved design value estimates of extreme precipitation events in the Czech Republic, *Climate Research* 33 (2007) 243–255.
- [49] WMO, Guide to Hydrological Practices, WMO-no. 168, World Meteorological Organization, Geneva, 2009.
- [50] L. Gardes, S. Girard, Estimation de quantiles extrêmes pour les lois à queue de type Weibull: une synthèse bibliographique, *Journal de la Société Française de Statistique* 154 (2013) 98–118.

- [51] C. de Valk, Approximation of high quantiles from intermediate quantiles, *Extremes* 19 (2016) 661–686.
- [52] M. A. Martin, On bootstrap iteration for coverage correction in confidence intervals, *Journal of the American Statistical Association* 85 (1990) 1105–1118.
- [53] T. J. DiCiccio, J. P. Romano, On bootstrap procedures for second-order accurate confidence limits in parametric models, *Statistica Sinica* (1995) 141–160.
- [54] Z. Rulfová, A. Buishand, M. Roth, J. Kysely, A two-component generalized extreme value distribution for precipitation frequency analysis, *Journal of Hydrology* 534 (2016) 659–668.

Literatuur

- Lochbihler, K., Lenderink, G., Siebesma, A. P. (2017), The spatial extent of rainfall events and its relation to precipitation scaling, *Geophys. Res. Lett.*, 44, 8629–8636.
- STOWA (2019) (auteurs: Beersma, J., Hakvoort, H., Jilderda, R., Overeem, A. & Versteeg, R.), Neerslagstatistiek en reeksen voor het waterbeheer 2019. STOWA rapport 2019-19, Stichting Toegepast Onderzoek Waterbeheer, Amersfoort.



Koninklijk Nederlands Meteorologisch Instituut

Postbus 201 | 3730 AE De Bilt
T 030 220 69 11 | www.knmi.nl