



---

# Grip op kwaliteit van Conference-peren met behulp van een Bayesiaans netwerk

GreenCHAINge G&F DP5 Export peren verre bestemmingen

Hajo Rijgersberg, Frank van de Geijn, Alex van Schaik, Don Willems, Esther Hogeveen



**WAGENINGEN**  
UNIVERSITY & RESEARCH

---



---

# Grip op kwaliteit van Conference-peren met behulp van een Bayesiaans netwerk

GreenCHAINge G&F DP5 Export peren verre bestemmingen

Auteurs: Hajo Rijgersberg, Frank van de Geijn, Alex van Schaik, Don Willems, Esther Hogeveen

Instituut: Wageningen Food & Biobased Research

Dit onderzoek is uitgevoerd door Wageningen Food & Biobased Research in opdracht van Stichting TKI Tuinbouw en gefinancierd door Stichting TKI Tuinbouw, GroentenFruit Huis, NFO, The Greenery, Vogelaar-Vredehof, Frupaks-Vernooij, Veiling Zuid Limburg, Jan Oskam BV, Agrofresh, Alviro Direct, in het kader van PPS TU 1406-096 Duurzame G&F ketens (GreenCHAINge G&F) (projectnummer BO-29.03-001-010).

Wageningen Food & Biobased Research  
Wageningen, november 2018

---

Openbaar

Rapport 1877  
ISBN 978-94-6343-553-6

---

Versie: definitief

Reviewer: Eelke Westra

Goedgekeurd door: Nicole Koenderink

Opdrachtgever: Stichting TKI Tuinbouw

Financier: Stichting TKI Tuinbouw, GroentenFruit Huis, NFO, The Greenery, Vogelaar-Vredehof, Frupaks-Vernooij, Veiling Zuid Limburg, Jan Oskam BV, Agrofresh, Alviro Direct

DOI: <https://doi.org/10.18174/465143>

ISBN: 978-94-6343-553-6

Dit rapport is gratis te downloaden op <https://doi.org/10.18174/465143/> of op [www.wur.nl/wfbr](http://www.wur.nl/wfbr) (onder publicaties).

© 2018 Wageningen Food & Biobased Research, instituut binnen de rechtspersoon Stichting Wageningen Research.

Het is de opdrachtgever toegestaan dit rapport integraal openbaar te maken en ter inzage te geven aan derden. Zonder voorafgaande schriftelijke toestemming van Wageningen Food & Biobased Research is het niet toegestaan:

- a. dit door Wageningen Food & Biobased Research uitgebrachte rapport gedeeltelijk te publiceren of op andere wijze gedeeltelijk openbaar te maken;
- b. dit door Wageningen Food & Biobased Research uitgebrachte rapport, c.q. de naam van het rapport of Wageningen Food & Biobased Research, geheel of gedeeltelijk te doen gebruiken ten behoeve van het instellen van claims, voor het voeren van gerechtelijke procedures, voor reclame of antireclame en ten behoeve van werving in meer algemene zin;
- c. de naam van Wageningen Food & Biobased Research te gebruiken in andere zin dan als auteur van dit rapport.

Postbus 17, 6700 AA Wageningen, T 0317 48 00 84, E [info.wfbr@wur.nl](mailto:info.wfbr@wur.nl), [www.wur.nl/wfbr](http://www.wur.nl/wfbr).  
Wageningen Food & Biobased Research is onderdeel van Wageningen University & Research.

Alle rechten voorbehouden. Niets uit deze uitgave mag worden verveelvoudigd, opgeslagen in een geautomatiseerd gegevensbestand of openbaar gemaakt in enige vorm of op enige wijze, hetzij elektronisch, hetzij mechanisch, door fotokopieën, opnamen of enige andere manier, zonder voorafgaande schriftelijke toestemming van de uitgever. De uitgever aanvaardt geen aansprakelijkheid voor eventuele fouten of onvolkomenheden.

---

# Inhoud

	<b>Woord vooraf</b>	<b>4</b>
	<b>Samenvatting</b>	<b>5</b>
<b>1</b>	<b>Introductie</b>	<b>7</b>
	1.1 Aanleiding en achtergrond	7
	1.2 Doel en scope van het ontwikkelen van een Bayesiaans netwerk voor peren	7
	1.3 Aanpak en opbouw rapport	8
<b>2</b>	<b>Dataconsolidatie</b>	<b>9</b>
	2.1 Databronnen	9
<b>3</b>	<b>Modelbeschrijving</b>	<b>10</b>
	3.1 Inleiding Bayesiaanse netwerken	10
	3.2 Basisstructuur model	12
	3.3 Opbouw stochasten en relaties	13
<b>4</b>	<b>Kalibratie</b>	<b>15</b>
	4.1 Aanvulling datafile met expertkennis	15
	4.2 Aanvullen model met expertregels	15
<b>5</b>	<b>Validatie</b>	<b>17</b>
	5.1 Expertbeoordeling	17
	5.2 Validatie(tool)	17
<b>6</b>	<b>Modelgebruik</b>	<b>19</b>
	6.1 Voorspellingsscenario's en beslissingsondersteuning	19
	6.2 Gevoeligheidsanalyse	22
	6.3 End user interface	24
<b>7</b>	<b>Conclusies &amp; discussie</b>	<b>27</b>
	7.1 Geschiktheid model voor kwaliteitsvoorspelling	27
	7.1.1 Scope model en dataset	27
	7.1.2 Hoeveelheid en kwaliteit data	28
	7.1.3 Validatie	28
	7.2 Kansen voor uitbreiding en toepassing van het model	29
	7.3 Voordelen Bayesiaans netwerk ten opzichte van andere modellen	30
	7.4 Inzichten op basis van het huidige model	30

---

# Woord vooraf

Het ontwikkelen van een nieuw Bayesiaans netwerk voor peren vanuit het niets, is een bijzonder leuk en leerzaam maar ook een intensief traject geweest. Het resultaat van het gehele ontwikkeltraject is een nieuwe manier van modelleren die helpt om grip te krijgen op kwaliteit in een versketen van peren, die door veel factoren beïnvloed wordt. In dit geval is het model voor verre bestemmingen ontwikkeld met focus op hardheid van peren, maar het model heeft veel potentie om doorontwikkeld te worden naar specifieke wensen voor bedrijven in de sector (telers, handel, toeleveranciers).

We zijn gestart met diverse sessies met experts (consultants/ onderzoekers) om een raamwerk op te zetten samen met de modelontwikkelaars/ onderzoekers. Alleen al het spreken van dezelfde taal is een uitdaging. Ondertussen zijn we een datafile gaan samenstellen. En daarna kwam de fase van het finetunen van het netwerk, opnieuw met experts (waar moeten we relaties leggen, hoe moeten we de klassen per categorie indelen, hoe om te gaan met restklassen, waar gaan we expertkennis toevoegen, hebben we nog andere datafiles, etc.). De eerste doorrekeningen van het model waren erg waardevol: checks op logische resultaten, leren wat het model wel kan en wat niet, waar missen we data? Maar ook, hoe kunnen we focus aanbrengen? Op een gegeven moment is het model gepresenteerd aan geïnteresseerde partners van GreenCHAINge G&F (Marco Kosten (Vogelaar-Vredehof), Ton de Weerd (The Greenery)). Ook hun feedback is meegenomen, de toegepaste expertregels zijn verbeterd, en het model aangevuld met een aantal praktijkrecords van zeetransporten naar China). Met de ontwikkeling van de validatietool, de toevoeging van data uit het laatste seizoen Kwalifruit en GreenCHAINge G&F en de visualisatie van een mogelijke user interface, kregen we steeds meer begrip van wat het model kan, hoe goed is het en wat het kan betekenen voor bedrijven.

Het is, met name vanuit het perspectief van een modelleur, gedurende het project steeds duidelijker geworden dat een Bayesiaans netwerk heel dicht bij de meetdata en (expert)kennis in het veld moet staan. Een Bayesiaans netwerk is een opstap naar uiteindelijke wiskundige modellering van de materie (in de vorm van vergelijkingen). Het is een goede manier die kan worden toegepast als je nog geen kennis hebt over de exacte relaties (in de vorm van formules) tussen de verschillende variabelen. Als je dicht op de data blijft, wordt ook het managen daarvan des te belangrijker. Het belangrijkste modelleerwerk zat hem in ons model in het kritisch en nauwkeurig kijken naar, en bewerken van, de onderliggende data en in mindere mate op het ontwikkelen van het Bayesiaanse netwerk zelf.

We willen met dit rapport de lezer beter inzicht geven in wat een Bayesiaans netwerk is, kan, en wat de mogelijkheden zijn om hiermee in een versketen (in dit geval van peren) grip te krijgen op kwaliteit. Er ligt een mooi basisnetwerk dat voor vele toepassingen verder ontwikkeld kan worden.

Onze dank gaat met name uit naar de partners Ton de Weerd en Marco Kosten voor hun waardevolle bijdrage aan het model in de vorm van kennis, feedback en data. Daarnaast bedanken we de overige partners van GreenCHAINge G&F en Kwalifruit en financier Stichting TKI Tuinbouw voor het mogelijk maken van de ontwikkeling van dit model en rapport.

---

# Samenvatting

De interesse vanuit de Nederlandse fruitsector om te gaan exporteren naar nieuwe afzetgebieden is de laatste jaren sterk gestegen. Kwaliteitsbeheersing van peren in deze nieuwe, onbekende ketens is vaak een uitdaging. De vraag is onder andere hoe de juiste partijen te selecteren en wat de beste condities zijn om ze met de juiste kwaliteit op bestemming te laten aankomen, met voldoende uitstalleven. In het project GreenCHAINge G&F DP5 Export peren verre bestemmingen, is een computermodel - een Bayesiaans netwerk - voor Conference-peren ontwikkeld dat hierbij kan helpen.

Het model berekent kansen dat bepaalde (on)bekende factoren zoals bijvoorbeeld seizoen, herkomst, pluktijdstip, toepassing SmartFresh, bewaar- en transportduur, uitstalcondities, leiden tot een bepaalde productkwaliteit op verschillende momenten in de keten. Dit wordt gedaan op basis van een combinatie van experimentele data (afkomstig uit GreenCHAINge-G&F- en Kwalifruit-experimenten) en praktijkgegevens. Ook is er expertkennis toegevoegd aan het model in de vorm van expertregels, daar waar geen data beschikbaar was maar wel kennis (bijvoorbeeld bij extreme condities temperatuur/transport). Het model staat eigenlijk heel dicht bij de data. Het geeft uitsluitel over specifieke situaties die zonder model lastig in te schatten zijn, omdat het moeilijk of bewerkelijk is voor de mens om *kwantitatieve* inschattingen te maken. Iedere persoon maakt een andere inschatting – het model kan zodoende als intermediair dienen tussen verschillende personen of stakeholders.

Met het huidige model kunnen succesvol scenario-berekeningen uitgevoerd worden voor de kwaliteitsfactor "hardheid". Een aantal scenario's zijn in dit rapport beschreven en met elkaar vergeleken op basis van de vraag: "Wat is de kans dat een partij aan het eind van een "verre bestemming" keten een hardheid heeft  $> 5 \text{ kg}/(0,5 \text{ cm}^2)$  en wat is dan de verwachte gemiddelde hardheid na uitstal?" Kansen bleken tussen de 30 en 60% te liggen bij partijen die bij oogst tussen de 5,5 en 6 kg  $/(0,5 \text{ cm}^2)$  waren. Kansen waren het grootst bij toepassing van SmartFresh of bij vroeg in het plukvenster geplukte peren. Er kunnen nog veel meer scenario's doorgerekend worden, bijv. een andere hardheid bij oogst, een specifiek seizoen. Met behulp van de validatietool blijkt dat het model bovenstaande vraag in 80% van de gevallen goed weet te voorspellen (gevalideerd met de huidige dataset). Het voorspellen van exact de juiste hardheidscategorie is moeilijker (strenger), dat wordt nu in 50% van de gevallen goed gedaan. Een voorspelling kan dan net één klasse naast de werkelijke waarde zitten, wat meteen als compleet fout wordt geteld.

Uitvoering van een gevoeligheidsanalyse geeft inzicht in welke factor de meeste invloed heeft op de voorspelde hardheid op een bepaald moment. In het huidige model blijkt dat hardheid na DC/transport vooral afhangt van hardheid op een bepaald moment; hardheid na uitstal na transport wordt meer ook beïnvloed door seizoen en wel of niet toepassen van SmartFresh. Factoren als pluk, herkomst, en duur van bewaring blijken veel minder van invloed.

Uitkomsten van het model helpen bewaarders/handelaren om bij te sturen in bijvoorbeeld bewaarcondities, of om voor deze partij van afzetkanaal te wisselen. Om deze functionaliteit praktischer te maken is het mogelijk het model te koppelen aan een user interface (zie de voorbeeld-user-interface in Hfst. 6.3). Inzichten uit het model kunnen ook bijdragen voor spelers in de sector om meer aandacht te besteden aan de schakels in de keten waarin nog veel kwaliteitsverbetering/-behoud behaald kan worden. Zo kan er in de toekomst gericht ingezet worden op effectievere teelt- en bewaarmethoden teneinde de kwaliteit van de peer te verbeteren.

Belangrijkste aandachtspunt bij het model is de datahoeveelheid en -kwaliteit. Datacollectie moet zo veel mogelijk volgens een standaardmethode verkregen worden. Het model wordt ook betrouwbaarder en bruikbaar als er meer data toegevoegd wordt, voor de verschillende condities en met meer aansluiting bij de praktijksituatie. Koppeling van het model aan een datamanagementsysteem van een bedrijf is een mogelijkheid. Ook het zelflerend maken van het model behoort tot de mogelijkheden.

---

Inhoudelijk kan het model op allerlei manieren verdiept en uitgebreid worden. Zo kunnen er meer kwaliteitsfactoren meegenomen worden en kan het model specifiek ingaan op bewaarcondities of teeltmaatregelen of een goede toepassing van SmartFresh.



---

# 1 Introductie

## 1.1 Aanleiding en achtergrond

Door het weggefallen van export van hardfruit naar Rusland is de interesse vanuit de Nederlandse fruitsector om te gaan exporteren naar nieuwe afzetgebieden de laatste jaren sterk gestegen. De overheid heeft zich ingezet voor het verkrijgen van nieuwe markttoegang in diverse verre bestemmingen zoals China, Brazilië en Vietnam, Mexico, Zuid-Afrika, India en binnenkort mogelijk ook Colombia. Kwaliteitsbeheersing van peren in deze nieuwe ketens is vaak een uitdaging. De kwaliteitseisen en behoeften kunnen in deze nieuwe markten anders zijn dan in de gangbare markten. De vraag is onder andere hoe de juiste partijen te selecteren en wat de beste condities zijn om ze met de juiste kwaliteit op bestemming te laten aankomen, met voldoende uitstalleven.

Een aantal partijen, actief in de sector, heeft zich verenigd binnen de publiek-private samenwerking (PPS) GreenCHAINge Groente & Fruit, gefinancierd door Stichting TKI Tuinbouw en diverse private bedrijven en instanties (Deelpakket 5: Nederlandse Fruittelers Organisatie, GroentenFruit Huis, Agrofresh, AlviroDirect, The Greenery, Veiling Zuid Limburg, Frupaks-Vernooij, Handelsmaatschappij Jan Oskam, Vogelaar-Vredehof) om te werken aan een kwaliteitsbeheerssysteem. Centraal staat hierbij de volgende generieke (smart chain) formule:

***Startkwaliteit + ketenconditie + (kwaliteitsmodel + technologie) = beheerste kwaliteit.***

Via experimenten binnen GreenCHAINge en een andere PPS, Kwalifruit, is gedurende vier jaar veel kennis verkregen op het gebied van kwaliteit van peren en uitstalleven, met betrekking tot variaties tussen herkomsten, seizoenen, gedragingen gedurende bewaring en transportsimulaties, en reacties op naaogstbehandelingen zoals SmartFresh. Naast deze data uit projecten worden er in de praktijk ook veel kwaliteitsmetingen gedaan en zijn er veel ervaringen die ook heel waardevolle kennis bevatten. In dit project hebben we deze data gekoppeld aan data en expertkennis uit de praktijk. Dit hebben we met behulp van een Bayesiaans netwerk gemodelleerd tot een kwaliteitsvoorspellingsmodel voor Conference-peren voor verre bestemmingen.

We achten deze techniek van modelleren geschikt voor het in kaart brengen van kwaliteit in versketens, in dit geval peer. Met behulp van een Bayesiaans netwerk kunnen scenario's worden doorgerekend, zoals het bepalen van de kans op een bepaalde hardheid in verschillende fases in de keten. Op basis van deze uitkomsten kan bijvoorbeeld worden bijgestuurd in bewaarcondities, die vervolgens opnieuw kunnen worden doorgerekend. Ook kan men op basis van die informatie kiezen om bijvoorbeeld van afzetkanaal te wisselen dan wel te hersorteren. Gevoeligheidsanalyses kunnen met een Bayesiaans netwerk gedaan worden om meer inzicht te krijgen in de effecten van bewaarcondities en -concepten, en teelteigenschappen op de latere kwaliteit. Op basis van kennis die op deze manier wordt opgebouwd, kan in de toekomst gericht ingezet worden op effectievere teelt- en bewaarmethoden teneinde de kwaliteit van peer te verbeteren.

## 1.2 Doel en scope van het ontwikkelen van een Bayesiaans netwerk voor peren

Met de ontwikkeling van het Bayesiaanse netwerk voor Conference-peren voor verre bestemmingen wordt beoogd om:

1. Een kwaliteitsvoorspelling te kunnen doen voor verwachte kwaliteit, in dit geval de kans op een bepaalde hardheid van een partij peren, op een bepaald moment in de keten, gegeven een aantal feiten van de partij (bijvoorbeeld herkomst, pluk, gemeten hardheid bij inslag, SmartFresh behandeld of niet). De uitkomst geeft een inschatting van de kans dat een bepaalde hardheidseis gehaald kan worden bij aankomst op verre bestemming.

- 
2. Een basismodel/structuur te hebben, welke verder uitgebreid kan worden op specifieke onderdelen, wanneer hier een duidelijke vraag ligt en er voldoende geschikte data (en/of kennis) aanwezig is. Het gaat hier dan bijvoorbeeld om uitbreiding van het model op andere kwaliteitsfactoren, andere teelt-/bewaar-/ketencondities, details van behandelingen, rassen of zelfs ander producten.
  3. Inzicht te krijgen in de voordelen van een Bayesiaans netwerk ten opzichte van andere beslissingsondersteunende en kwaliteitsvoorspelmodellen.
  4. Antwoord te krijgen op een aantal specifieke vragen zoals: welke teelt-/naoogstfactoren hebben de meeste invloed op de hardheid van peren in een lange keten en in welke mate? In hoeverre is het effect van SmartFresh op hardheid na uitstal afhankelijk van het seizoen of de herkomst of het pluktijdstip? Deze antwoorden kunnen ook richting geven aan welke onderdeel van het model verder aangevuld/uitgewerkt moet.

Onderzoekers van Wageningen Food & Biobased Research hebben een objectief en onafhankelijk ontwikkeltraject uitgevoerd om dit netwerk/model te creëren. Het netwerk is op dit moment ingericht op basis van een vraag die er vanuit de handel leeft: is een specifieke partij geschikt om naar een verre bestemming te sturen? Hierbij zijn vele factoren in meer of minder mate van invloed. Op basis van beschikbare data en een inschatting van experts is er een selectie van factoren gemaakt welke het meest belangrijk geacht worden. De datasets van Conference-peren uit Kwalifruit en GreenCHAINge vormden een goede basis met name op het gebied van hardheid. Hier is het model mee opgebouwd en later met data uit de praktijk aangevuld.

In de toekomst kunnen met name handelspartijen uit de sector steeds betere voorspellingen doen op verwachte kwaliteit, als ze het huidige model koppelen aan (eigen) datamanagement en kwaliteitscontroledata. Door hiervan te leren kunnen ketens steeds beter afgestemd worden op behoeften.

Hoewel het model beperkt op specifiek teelt- en bewaarcondities ingaat, geeft het model ook voor telers, bewaarders, toeleveranciers belangrijke aanwijzingen. Hoe sterker de voorspelde kwaliteit in het model afhankelijk blijkt van telers, bewaarfactoren, behandelingen, des te belangrijker is het om hier in de toekomst meer begrip van te krijgen, hier data/kennis op te verzamelen en het model mee uit te breiden.

## 1.3 Aanpak en opbouw rapport

In hoofdstuk 2 bespreken we eerst de data waarop het model gebaseerd is. De data zijn namelijk in hoge mate leidend voor het model; het model wordt als het ware vrij direct "bovenop" de data gebouwd. Weliswaar bestaat er in principe eerst een impliciet model volgens welke het onderzoek wordt verricht en data wordt gemeten en verzameld, maar om het rapport helder te houden, bespreken we eerst de data en dan het expliciete model, dat wil zeggen het Bayesiaanse netwerk. Data kan ook worden aangevuld met expertkennis. Daarna in hoofdstuk 3 wordt de opbouw van het model uitgelegd, de basisstructuur met alle stochasten en relaties en een voorbeeldbeschrijving hoe het model is aangevuld met expertregels. In hoofdstuk 4 beschrijven we de kalibratie en validatie van het Bayesiaanse netwerk. Dit houdt onder andere in het inlezen van de data en het model checken op logische voorspellingen en een validatie van het model middels de zogenaamde 70-30-methode. In hoofdstuk 5 gaan we het model gebruiken om een aantal antwoorden te krijgen op vragen, door verschillende voorspellingsscenario's te draaien, een gevoeligheidsanalyse te doen. Daarnaast tonen we een voorbeeld end user interface om visueel te maken hoe het model in de praktijk gebruikt kan worden en duidelijk te maken dat er verschillende uitbreidingsmogelijkheden zijn. Ten slotte sluiten we af met conclusies en een discussie waarin enkele bijzonderheden en uitdagingen van Bayesiaanse netwerken in het algemeen en specifiek dit model mee te kampen heeft, maar ook de kansen die er liggen voor het model.

---

## 2 Dataconsolidatie

### 2.1 Databronnen

Voor het model wordt gebruik gemaakt van een Excel-file bestaande uit kwaliteitsmetingen (op dit moment hardheidsmetingen) afkomstig uit drie databronnen: data afkomstig van experimenten uitgevoerd binnen de projecten Kwalifruit en GreenCHAINge en van praktijkpartijen van The Greenery.

De totale datafile bestaat op dit moment uit 554 regels. Een regel bestaat uit de metingen en omstandigheden van een batch in de loop van de tijd, zoals ook het model uiteindelijk is opgebouwd (zie Hoofdstuk 3). Als er aan één batch met dezelfde behandeling en bewaaromstandigheden meerdere metingen in de tijd zijn uitgevoerd dan zijn deze op 1 regel terechtgekomen. Per batch zijn gemiddelde waarden genoteerd van telkens 20 samples. Nagenoeg elke behandeling is per meetmoment in tweevoud gemeten (2 x 20 peren).

Hieronder een overzicht van de hoeveelheid regels in de files vanuit de verschillende projecten (Tabel 1).

**Tabel 1. Aantal datarecords per gebruikte datafile.**

	Seizoenen	Totaal aantal regels
Kwalifruit	2014-2018	450
GreenCHAINge	2015-2018	84
The Greenery	2015-2018	20

Voor Kwalifruit zijn gedurende vier seizoenen hardheidsmetingen na oogst en bewaring uitgevoerd aan peren afkomstig van 18 locaties verspreid over Nederland (Zuid, Midden, Noord). Er is getracht om telkens van dezelfde percelen te oogsten. Peren zijn na de oogst getransporteerd naar Randwijk, waar ze per partij gemixt zijn voor een representatief beeld van de batch. De volgende dag zijn er hardheidsmetingen (GUSS-penetrator; in kg/(0,5 cm<sup>2</sup>)) en andere kwaliteitsmetingen uitgevoerd. De overgebleven peren zijn na de gebruikelijke wachttijd in ULO-bewaring geplaatst (commerciële locatie: Oskam, Meteren). Een deel van de peren is één week na de oogst met SmartFresh behandeld (volgens commercieel protocol Agrofresh) en na de wachttijd ook bij Oskam bijgeplaatst. Na verschillende bewaarduren (voornamelijk 6 en 8-9 maanden) zijn de partijen uit bewaring gehaald waarna opnieuw stevigheid bepaald werd. Partijen werden ook uitgesteld één week bij 10°C of in sommige gevallen 18°C. In een aantal jaren zijn er ook "China-simulaties" uitgevoerd waarbij partijen na 6 maanden ULO-bewaring ook nog 6 weken bij normale condities koud "getransporteerd" werden, waarna opnieuw stevigheid gemeten werd voor en na uitstal.


Het project GreenCHAINge G&F is in 2015 gestart om dit lange transport zoals hierboven beschreven, verder te optimaliseren. Er is met een selectie van de herkomsten van Kwalifruit gewerkt, en met andere behandel-, bewaar- en transportomstandigheden. Er is alleen gebruik gemaakt van data van normale behandelingen en niet van experimentele behandelingen die ook binnen GreenCHAINge G&F onderzocht zijn (bijvoorbeeld SmartFresh-behandeling na bewaring, speciale verpakkingen, Biofresh). Deze keuze is gemaakt om het model praktisch te houden, voornamelijk omdat deze behandelingen in de praktijk nog geen algemene toepassing kennen.

Er is ook een aantal regels toegevoegd vanuit praktijkmetingen van The Greenery aan partijen die naar China getransporteerd zijn waarbij metingen na oogst, bij vertrek en bij aankomst gemeten zijn. Deze partijen zijn van één teler afkomstig; van deze partijen zijn geen uitstalmetingen beschikbaar.

# 3 Modelbeschrijving


## 3.1 Inleiding Bayesiaanse netwerken

Een Bayesiaans netwerk is een wiskundig model dat bestaat uit stochasten; dat wil zeggen variabelen waarvan elke waarde een bepaalde waarschijnlijkheid heeft. Dit is het gemakkelijkst om uit te leggen aan de hand van een simpel voorbeeld<sup>1</sup>: twee gebeurtenissen kunnen ertoe leiden dat gras nat wordt: een spuit die geactiveerd wordt, of regen. Regen heeft een direct effect op het gebruik van de spuit, namelijk als het regent, is de spuit normaal gesproken buiten gebruik. Deze situatie kan gemodelleerd worden met Bayesiaans netwerk:



**Figuur 1. Een eenvoudig Bayesiaans netwerk. Regen (Rain) beïnvloedt of de spuit (sprinkler) is geactiveerd, en zowel regen als de spuit hebben tot effect dat het gras nat (grass wet) is.**

Elke variabele heeft twee mogelijke waarden: T (voor true) en F (voor false). De kansen dat de variabelen de waarden T of F hebben, worden gegeven door achterliggende waarschijnlijkheidstabellen, zie onderstaande figuur. Bijvoorbeeld, de kans dat het gras nat is hangt af van de waarden van de andere twee variabelen (die we links van de verticale lijn zien). De waarschijnlijkheden in één regel van een tabel tellen op tot 1 (of: 100%). De waarschijnlijkheidstabellen worden conditioneel genoemd, omdat de kans dat een waarde geldt vaak afhangt van de waarden van andere variabelen. In het voorbeeld is dat alleen voor de variabele 'Rain' niet het geval.



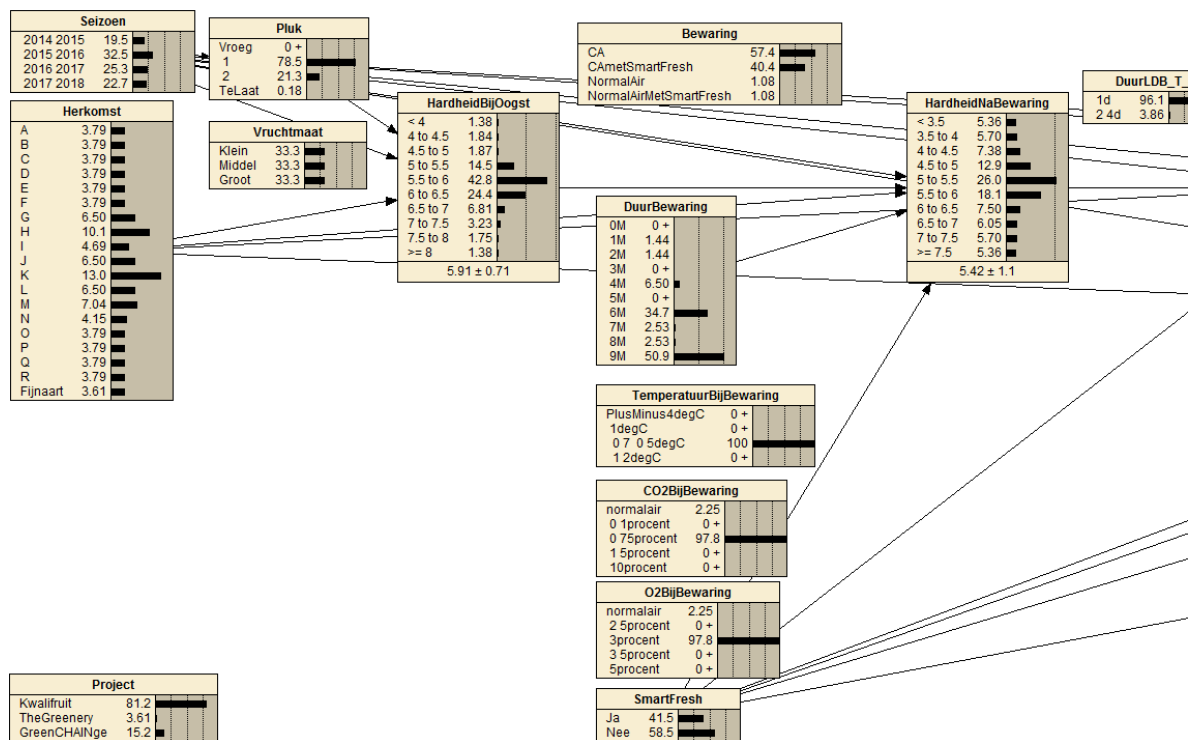
**Figuur 2. Het Bayesiaanse netwerk met onderliggende conditionele waarschijnlijkheidstabellen.**

<sup>1</sup> Wikipedia. Bayesian network. 2018. [https://en.wikipedia.org/wiki/Bayesian\\_network](https://en.wikipedia.org/wiki/Bayesian_network). Creative Commons Attribution-ShareAlike License (<https://creativecommons.org/licenses/by-sa/3.0/>)

De waarschijnlijkheden worden doorgaans geleerd uit (meet)data. Het is vaak moeilijk om hiervoor als expert oordelen te geven (vaak te veel, te grote tabellen, met te veel afhankelijkheden van andere variabelen). Wel kan een expertoordeel toegevoegd worden, het specificeren van een zogenaamd *belief*, een subjectief expertoordeel. De kern van de zaak is dat zo'n belief beter is dan als je over die stochast *helemaal* niets weet en uit zou gaan van gelijke kansen voor elke waarde van die stochast.

Er bestaan verschillende softwarepakketten om Bayesiaanse netwerken in te modelleren en allerlei acties mee uit te voeren zoals het inlezen van data en het plegen van gevoeligheidsanalyses. Voorbeelden van zulke pakketten zijn Netica en Hugin. Voor het perenmodel is Netica gebruikt.

In een grafische weergave van een Bayesiaans netwerk in Netica, wordt een stochast als een blok weergegeven en de waarschijnlijkheden van diens waarden door middel van de zwarte balkjes (zoals de verschillende gele blokken (variabelen) met de zware balkjes in (Figuur 3). Alle waarden tezamen vormen met hun waarschijnlijkheden een verdeling, bijvoorbeeld een normale verdeling. De bijbehorende precieze percentages (waarschijnlijkheden) staan links naast de balkjes vermeld. Bij de continue variabelen, zoals de hardheden, worden onderin het blok bovendien het gemiddelde en de standaarddeviatie van de stochast gegeven. Stochasten kunnen van elkaar afhankelijk zijn. De afhankelijkheden worden weergegeven met pijlen (relaties) tussen elkaar, waardoor een *netwerk* van stochasten wordt verkregen, een Bayesiaans netwerk.



**Figuur 3. Fragment van het Bayesiaanse netwerk over de kwaliteit van peer ter illustratie van verschillende stochasten.**

De afhankelijkheid van een stochast van andere stochasten wordt gerepresenteerd door middel van een waarschijnlijkheidstabel (zie Figuur 4 voor een voorbeeld). Voor iedere combinatie van waarden van de *onafhankelijke stochasten* (in dit geval Hardheid NaLDB\_T\_S5degC en SmartFresh) waar de betreffende *afhankelijke stochast* (in dit geval Hardheid na uitstal na bewaring) van afhankelijk is, worden de waarschijnlijkheden gegeven dat de *afhankelijke stochast* een mogelijke waarde krijgt (klassen 0-1, 1-2, ..., > = 8).

Node: HardheidNaUitstalNaBe\_

Chance ▾ % Probability ▾

Apply OK Reset Close

HardheidNaLDB_T_S5degC	SmartFresh	0 to 1	1 to 2	2 to 3	3 to 4	4 to 5	5 to 6	6 to 7	7 to 8	>= 8
< 3.5	Ja	100								
< 3.5	Nee	50	50							
3.5 to 4	Ja		100							
3.5 to 4	Nee	0	50	50	0	0	0	0	0	0
4 to 4.5	Ja	0	0	100	0	0	0	0	0	0
4 to 4.5	Nee	12.5	62.5	25	0	0	0	0	0	0
4.5 to 5	Ja	0	8.333	58.333	16.667	16.667	0	0	0	0
4.5 to 5	Nee	4.545	36.364	54.545	4.545	0	0	0	0	0
5 to 5.5	Ja	0	5	25	10	30	30	0	0	0
5 to 5.5	Nee	0	29.508	55.738	14.754	0	0	0	0	0
5.5 to 6	Ja	0	0	19.444	8.333	8.333	52.778	11.111	0	0
5.5 to 6	Nee	7.463	22.388	40.298	29.851	0	0	0	0	0
6 to 6.5	Ja	0	0	0	15.385	7.692	15.384	46.154	15.385	0
6 to 6.5	Nee	5.263	10.526	21.053	47.369	15.789	0	0	0	0
6.5 to 7	Ja	0	0	0	0	0	0	40	60	0
6.5 to 7	Nee	0	0	14.286	71.428	14.286				
7 to 7.5	Ja							40	60	
7 to 7.5	Nee				50	50				
>= 7.5	Ja							40	60	
>= 7.5	Nee				50	50				

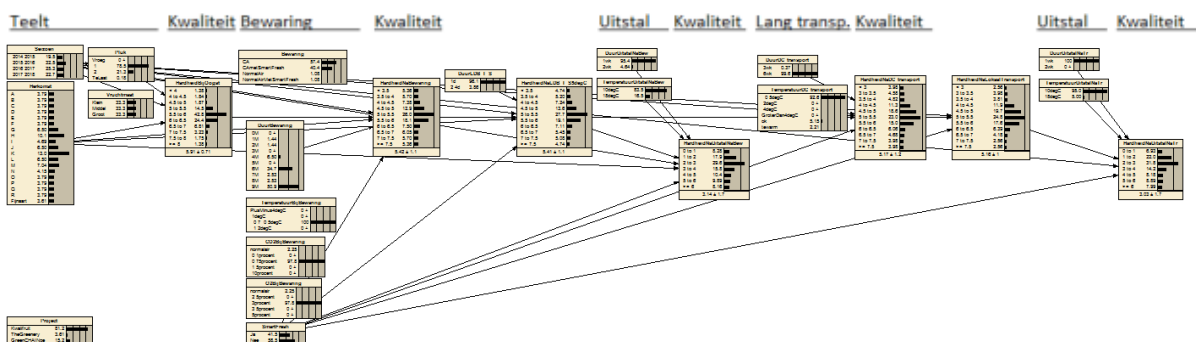
**Figuur 4. Waarschijnlijkheidstabel voor de stochast Hardheid na uitstal na bewaring. De waarschijnlijkheden in één regel tellen op tot 100%. Bijvoorbeeld, als de hardheid tijdens de vorige fase, de HardheidNaLDB\_T\_S5degC tussen 6 en 6,5 zit en SmartFresh is 'Ja', dan is de waarschijnlijkheid dat de hardheid na uitstal na bewaring tussen de 5 en 6 zal zitten 15% (afgerond).**

De waarden in de waarschijnlijkheidstabellen van de stochasten worden geleerd uit de datafile(s). Aanvullingen kunnen gemaakt worden door samen met experts inschattingen te geven voor die records waar geen data beschikbaar voor waren. Het beste is om dat te doen op grond van de records die wel gegeven zijn (en op basis daarvan bijvoorbeeld translaties te doen), zodat de expertkennis goed is ingebed in de experimentele kennis.

## 3.2 Basisstructuur model

Het opgebouwde model voor peer representeert hardheden door de keten heen, vanaf oogst via bewaring tot uitstal, en deze hangen van elkaar af (in de zin dat iedere hardheid afhangt van de hardheid uit de voorgaande fase). De verschillende hardheden zijn ook afhankelijk van condities zoals duur, temperatuur, toepassing van SmartFresh, en partijeigenschappen als herkomst (telercode), bewaarperiodes en pluktijdstip.

Figuur 3 toonde al een fragment van het model en Figuur 5 toont een compleet overzicht van het huidige model.



**Figuur 5. Het Bayesiaans netwerk voor peren uitgezoomd. De verschillende fases in de keten zijn bovenaan in de figuur aangegeven. Aan het eind van iedere fase wordt de kwaliteit weergegeven na die fase.**

---

De horizontale as van het model is de tijd. Iedere kolom van variabelen representeert een fase in de keten dan wel condities of daaruit volgende kwaliteit na een fase.

- De eerste twee kolommen vormen de teelt. Herkomst (ofwel: teler/perceel – geanonimiseerd), seizoen (dat wil zeggen bewaar seizoen) en pluk (te vroeg, 1 (vroeg in plukvenster), 2 laat in plukvenster, of te laat) zijn op dit moment de belangrijkste variabelen in de teeltfase van het model.
- De derde kolom representeert de kwaliteit van de peren direct na oogst. Hardheid is daarin op dit moment de primaire kwaliteitsvariabele. In de toekomst kan het model uitgebreid worden met bijvoorbeeld de variabelen 'kleur' en 'inwendig rot'.
- De vierde kolom geeft de bewaarcondities weer, in het bijzonder duur en wel of niet toepassen van SmartFresh.
- De vijfde kolom drukt de kwaliteit van de peren na deze bewaarcondities uit.
- De zesde kolom en zevende kolom staan voor de tijd van transport naar sorteer-/verpakkingslocatie en de tijd van het sorteren en verpakken zelf. In ons geval is hier nog geen variatie in aangebracht in de data. De waarden van hardheid (kolom 7) is dus hetzelfde als kolom 5
- De achtste kolom geeft de condities bij uitstal na bewaring en de negende kolom de kwaliteit na uitstal.
- De tiende kolom bevat de condities bij lang transport (containertransport), waarna de elfde kolom de daarna verkregen kwaliteit geeft.
- De twaalfde kolom staat voor hardheid na lokaal transport. In ons geval is hier nog geen variatie in aangebracht in de data (geen input). De waarden van kolom 12 zijn dus hetzelfde als kolom 11.
- De dertiende en veertiende kolom tenslotte representeren respectievelijk de condities bij uitstal na lang transport en de daaruit resulterende kwaliteit.

### 3.3 Opbouw stochasten en relaties

Het is bij het modelleren belangrijk om de *juiste* causale relaties tussen variabelen aan te leggen; de kwaliteit van het model staat of valt hiermee. Het is ook gewenst om veel variabelen op te nemen en met name veel relaties tussen deze variabelen aan te leggen, om alle mogelijke afhankelijkheden in het model te hebben opgenomen. Echter, wanneer hoeveelheden data beperkt zijn, moet er juist bezuinigd moet worden op het aantal variabelen en relaties dat gelegd wordt tussen twee variabelen, om voldoende records over te houden. Er bestaat dus een trade-off tussen enerzijds afhankelijkheid van variabelen en anderzijds aantallen records waarop deze afhankelijkheden kunnen worden gebaseerd. In een setting waarin sprake is van een steeds groeiende datageneratie, is het verstandig om te kijken of na verloop van tijd relaties waarop in eerste instantie wellicht werd bezuinigd, alsnog toe te voegen.

Voor het perenmodel is gekozen om eerst alle ketenstappen met conditie (duur van de fase, bewaarcondities, temperatuur, SmartFresh) te laten resulteren in een daaropvolgende hardheid en deze dient weer als input voor een vervolgstap. Echter, sommige factoren aan het begin van een keten hebben een blijvende invloed of pas een invloed welke in een latere fase pas speelt en aldus wordt opgemerkt. In deze gevallen leggen we dus verbindingen tussen de betreffende factoren, de hardheid in een volgende stap maar ook (direct) met hardheden na verdere ketenstappen. Voorbeelden van factoren die op deze manier met meerdere ketenfasen in het model verbonden zijn: het gebruik van wel of geen SmartFresh-behandeling na de oogst, herkomst, seizoen, en pluk. Deze aanpak is nodig omdat het hardheidsverloop van twee gelijke hardheden in een bepaalde (late) fase verschillend is als op de ene batch peren wel SmartFresh is toegepast en op de andere niet, of als de batches peren uit een verschillend seizoen afkomstig zijn (of verschillende herkomst of pluk). Voor het perenmodel zijn na kalibratie van het model en het uitvoeren van gevoeligheidsanalyses (hoofdstuk 4 en 6) extra verbindingen aangebracht of weer verwijderd als ze niets toevoegen of de uitkomst juist verzwakken.

De indeling van een stochast (waar de klassiegrenzen liggen) wordt bepaald door de data. Op dit moment zijn de stochasten als volgt gedefinieerd:

**Tabel 2. Overzicht van variabelen met hun exacte naam in het model en de mogelijke waarden die zij kunnen hebben.**

Naam stochast	Exacte naam in model	Mogelijke waarden
Seizoen	Seizoen	2014-2015; 2015-2016; 2016-2017; 2017-2018
Pluk	Pluk	Vroeg; 1; 2; laat
Herkomst	Herkomst	A t/m R; Fijnaart
Hardheid bij oogst	HardheidBijOogst	< 4; 4-4,5; ...; 7,5-8; ≥ 8
Duur bewaring	DuurBewaring	0 M; 1 M; ...; 8 M; 9 M
Temperatuur bij bewaring	TemperatuurBijBewaring	-1,2 °C; -0,7 - -0,5 °C; 1 °C; ≈ 4 °
SmartFresh	SmartFresh	Ja, nee
Hardheid na bewaring	HardheidNaBewaring	< 3,5; 3,5-4; ...; 7-7,5; ≥ 7,5
Duur laatste dag bewaring + transport + sorteren	DuurLDB_T_S	1 d; 2-4 d
Hardheid na laatste dag bewaring + transport + sorteren	HardheidNaLDB_T_S	< 3,5; 3,5-4; ...; 7-7,5; ≥ 7,5
Duur uitstal na bewaring	DuurUitstalNaBew	1 wk; 2 wk
Temperatuur uitstal na bewaring	TemperatuurUitstalNaBew	10 °C; 18 °C
Hardheid na uitstal na bewaring	HardheidNaUitstalNaBew	0-1; 1-2; ...; 5-6; ≥ 6
Duur DC + transport	DuurDC_transport	3 wk; 6 wk
Temperatuur DC + transport	TemperatuurDC_transport	-0,5 °C; 2 °C; 4 °C; > 4 °C; OK; te warm
Hardheid na DC + transport	HardheidNaDC_transport	< 3; 3-3,5; ...; 7-7,5; ≥ 7,5
Hardheid na lokaal transport	HardheidNaLokaalTransport	< 3; 3-3,5; ...; 7-7,5; ≥ 7,5
Duur uitstal na transport	DuurUitstalNaTr	1 wk; 2 wk
Temperatuur uitstal na transport	TemperatuurUitstalNaTr	10 °C; 18 °C
Hardheid na uitstal na transport	HardheidNaUitstalNaTr	0-1; 1-2; ...; 5-6; ≥ 6



---

## 4 Kalibratie

De in hoofdstuk 2 beschreven data laden we in het model in. Op deze manier wordt het model gekalibreerd. Dit wordt ook wel het trainen of leren van het Bayesiaanse netwerk genoemd. Dit is een standaardfunctionaliteit in ieder Bayesiaans netwerkpakket. De kolommen en hun waarden in de datafile moeten exact overeenkomen met de namen van de variabelen in het model. Het resultaat is een gekalibreerd model dat de gemeten en gerealiseerde waarden van alle data weergeeft in de distributies van de variabelen en de relaties tussen de variabelen. Hierna voegen we expertkennis toe.

### 4.1 Aanvulling datafile met expertkennis

De informatie van één batch in de datafile vertoont regelmatig hiaten per regel, omdat in de projecten niet altijd van elke batch op alle momenten gemeten is. Een Bayesiaans netwerk kan hier mee om gaan, maar het verliest hierbij wel kracht en zekerheid en doet dus een minder sterke voorspelling voor dat meetmoment. Het model gaat in geval van missende informatie uit van gelijke kansen op elke waarde van een stochast – resulterend in een uniforme verdeling voor die stochast – en rekent daarmee verder. Aanvulling met expertkennis biedt hier een oplossing om tot een reëlere inschatting van de werkelijkheid te komen. Bijvoorbeeld: een expert weet dat bepaalde waarden in de praktijk niet of weinig voorkomen. Het model zou bij gebrek aan kennis hier allemaal een gelijke waarschijnlijkheid aan toekennen. De kennis van de expert geeft dan een reëlere inschatting van de werkelijkheid dan wanneer er helemaal geen informatie ingevuld is. Met de verbeterde kennis kan het model vervolgens verder rekenen.

Een aantal voorbeelden in de opgebouwde datafile waarbij dit gedaan is:

- Hardheid van peren behandeld met SmartFresh zijn na bewaring bij het Kwalifruit-project in 2015-2016 niet apart gemeten, omdat ze nog verder gevolgd werden in de transportsimulatie. Uit de data van GreenCHAINge G&F zijn in datzelfde jaar voor een paar herkomsten deze metingen wel gedaan. Hieruit bleek dat de waarden voor peren met SmartFresh gemiddeld 0,1 kg hoger waren direct na bewaring dan de metingen na het 6 weken transport. We hebben hier besloten om de waarden van alle Kwalifruit-herkomsten, peren behandeld met SmartFresh, 6 maanden bewaard, van het oogstjaar 2015, direct na bewaring dus af te laten leiden van de metingen na het transport van 6 weken (alle waarden + 0,1 kg). Dit geeft een reëler beeld dan dat het netwerk een kans berekent op basis van alle data in de file en hier een uniforme verdeling kiest omdat het geen input heeft.
- Er is ook een formule ingevoerd voor de verwachte uitstalgegevens van bovenstaande partijen waarbij een onderscheid gemaakt wordt voor pluk 1 = 0,25 kg hoger dan uitstal na 6 weken transport; pluk 2 = 0,6 hoger dan na uitstal bij 10°C na 6 weken transport.
- In de projecten hebben we niet vaak variaties in transportduren aangelegd. Transportduur vanaf bewaarlocatie naar Wageningen vond vaak plaats in één dag. Voor het gemak zijn de hardheden direct na bewaring en de gemeten waarden in Wageningen als gelijk aangenomen omdat de verwachting is dat de effecten hiervan minimaal zijn geweest. In de praktijk bij langere transporttijden en hogere temperaturen zou hier wel rekening mee gehouden moeten worden.

### 4.2 Aanvullen model met expertregels

Een andere manier om om te gaan met missende data is om op basis van bestaande data aanvullende expertregels te formuleren in het model, op basis waarvan vervolgens de missende data kunnen worden afgeleid.

---

Een voorbeeld in het model waarbij dit gedaan is het volgende: Er is een regel geformuleerd omtrent het effect van hogere transporttemperaturen (dan  $-0,5^{\circ}\text{C}$ ), een kortere transportduur (van 3 weken naar 6 weken), en het toepassen van SmartFresh:

- een verhoging van de temperatuur van  $-0,5^{\circ}\text{C}$  tot  $2^{\circ}\text{C}$  zorgt (bij aanname/inschatting dus) voor een hardheidsverlaging van 2 punten, en van  $2^{\circ}\text{C}$  naar  $4^{\circ}\text{C}$  gaat daar nog eens 1 extra hardheidspunt van af. In geval van een kortere transportduur (van 6 naar 3 weken) worden deze hardheidstoenames gehalveerd, wat ook gebeurt bij toepassing van SmartFresh.  
Indien deze beide veranderingen (dus kortere transportduur en toepassing SmartFresh) tegelijkertijd plaatsvinden, vindt een kwartering van de genoemde effecten plaats ( $0,5 \times 0,5$ ).
- Bij een temperatuur tijdens transport  $> 4^{\circ}\text{C}$  vindt een geheel andervormige regel plaats: indien de hardheid tussen 6 en 10 ligt, dan komt deze tussen de 1.5 en 2 te liggen; indien de hardheid tussen 5 en 6 ligt, dan gaat die naar 1-1.5; en bij een hardheid van 0 tot 5 wordt deze 0 tot 1; bij zowel 3 en 6 weken transportduur en/of toepassing van SmartFresh.

---

## 5 Validatie

De validatie is op twee manieren uitgevoerd: er is aan de hand van scenario's gecheckt of het model logische voorspellingen geeft. Deze activiteit komt neer op het geven van een expertoordeel over het model. Vervolgens is het model gevalideerd op basis van een klassieke validatiemethode: de zogenaamde 70-30 methode, waarbij op basis van 70% van de data het model gekalibreerd wordt en de overige 30% gebruikt worden om op basis van de inputwaarden in deze records het model voorspellingen te laten doen en deze te vergelijken met de outputwaarden in de betreffende records.

### 5.1 Expertbeoordeling

Na kalibratie en toevoeging van expertkennis kunnen we het model inspecteren op logica. In zo'n check kijk je op consistentie, of gedrag dat je verwacht ook werkelijk gebeurt. Dit doen we door gericht bepaalde waarden van variabelen aan te klikken (bewaaramstandigheden, seizoen, herkomst, toepassing SmartFresh, etc.) en te zien hoe de waarden van andere variabelen (hardheden bijvoorbeeld) daardoor veranderen. Voor bepaalde relaties ken je de onderliggende data en weet je hoe het zou moeten veranderen.

We hebben bij onze check vooral naar een initiële hardheid van rond de 5-6 kg gekeken, omdat er voor overige hardheden niet zoveel data is. We hebben ons gericht op het punt of de hardheidsontwikkeling door de verdere keten logisch is, want de peer rijpt langzaam. Dit zien we nu door de keten heen gebeuren. Bij uitstal zien we de peer volgens verwachting snel zachter worden. Dit komt met data en expertkennis overeen.

De expertbeoordeling heeft ook de volgende inzichten over het model gegeven en gezorgd voor een aantal aanpassingen:

1. Huidige data is vooral van de gangbare situatie: goed product. Het model is op dit moment minder geschikt om extreme situaties te voorspellen.
2. De klasseindeling van de hardheidsvariabelen is van invloed op een logisch verloop van (gemiddelde) kwaliteit en de mate hiervan. Dit heeft te maken met het *aantal* zogenaamde "restklassen", de heel lage hardheidsklassen en heel hoge klassen. Hoe meer van dit soort klassen er zijn, hoe meer deze restklassen in de kansen meegenomen worden en de voorspelling minder realistisch/logisch maken. Het is dus zaak om een redelijk, realistisch aantal lage en hoge klassen voor de betreffende hardheidsvariabelen te definiëren. Dit effect wordt versterkt als er weinig data beschikbaar is.
3. De check en het 'spelen' met het model is belangrijk om de juiste relaties te leggen. Op basis van deze eerste beschouwingen hebben we herkomst, pluk, seizoen en SmartFresh met meerdere hardheden door de keten heen verbonden, omdat deze factoren daar later nog van invloed op bleken te zijn (zie ook hoofdstuk 3.3).

### 5.2 Validatie(tool)

De ontwikkelde validatietool geeft een beeld van de robuustheid van het model. Het geeft aan in hoeveel gevallen bij een run met een deel van de data (30%) er eenzelfde voorspelling gedaan wordt in welke hardheidsklasse het meest waarschijnlijk is dat deze partij zal vallen, als met de overige 70% van de data (procentueel weergegeven noemen we dit de *performance*). Herhaling van de validatie geeft de variatie van de validatieresultaten. Als het model een hoge performance en lage variatie in validatie is dit een belangrijke indicatie dat het model robuuste voorspellingen doet.

In het geval van ons perenmodel en de scenario's in 4.2 kijken we naar een in duplo uitgevoerde validatie, betreffende de voorspelling van kans op hardheid > 5 na DC (verpakking en transport) en lang koud transport (6 weken bij -0,5°C) (Tabel 3 en 4).

**Tabel 3. Validatieresultaten hardheid na DC en ver transport (run 1). Horizontale as: gemeten klasse; verticale as: voorspelde klasse.**

Result State	min	max	Expected										Total			
			Hardheid NaDC_transport#s0	Hardheid NaDC_transport#s1	Hardheid NaDC_transport#s2	Hardheid NaDC_transport#s3	Hardheid NaDC_transport#s4	Hardheid NaDC_transport#s5	Hardheid NaDC_transport#s6	Hardheid NaDC_transport#s7	Hardheid NaDC_transport#s8	Hardheid NaDC_transport#s9		Hardheid NaDC_transport#s10		
HardheidNaDC_transport#s0	#DIV/0!	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0
HardheidNaDC_transport#s1	3	3.5	0	0	0	0	0	0	0	0	0	0	0	0	0	0
HardheidNaDC_transport#s2	3.5	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0
HardheidNaDC_transport#s3	4	4.5	0	0	0	1	0	0	0	0	0	0	0	0	0	1
HardheidNaDC_transport#s4	4.5	5	0	1	0	2	5	6	0	0	0	0	0	0	0	14
HardheidNaDC_transport#s5	5	5.5	0	0	0	3	6	21	12	1	0	0	0	0	0	43
HardheidNaDC_transport#s6	5.5	6	0	0	0	0	0	2	6	3	0	0	0	0	0	11
HardheidNaDC_transport#s7	6	6.5	0	0	0	0	0	0	0	0	0	0	0	0	0	0
HardheidNaDC_transport#s8	6.5	7	0	0	0	0	0	0	0	1	0	0	0	0	0	1
HardheidNaDC_transport#s9	7	7.5	0	0	0	0	0	0	0	0	0	0	0	0	0	0
HardheidNaDC_transport#s10	7.5	#DIV/0!	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Total			0	1	0	6	11	29	18	5	0	0	0	0	0	70

**Tabel 4. Validatieresultaten hardheid na DC en ver transport (run 2). Horizontale as: gemeten klasse; verticale as: voorspelde klasse.**

Result State	min	max	Expected State										Total			
			Hardheid NaDC_transport#s0	Hardheid NaDC_transport#s1	Hardheid NaDC_transport#s2	Hardheid NaDC_transport#s3	Hardheid NaDC_transport#s4	Hardheid NaDC_transport#s5	Hardheid NaDC_transport#s6	Hardheid NaDC_transport#s7	Hardheid NaDC_transport#s8	Hardheid NaDC_transport#s9		Hardheid NaDC_transport#s10		
HardheidNaDC_transport#s0	#DIV/0!	3	0	0	0	0	0	0	0	0	0	0	0	0	0	0
HardheidNaDC_transport#s1	3	3.5	0	0	0	0	0	0	0	0	0	0	0	0	0	0
HardheidNaDC_transport#s2	3.5	4	0	1	0	0	0	0	0	0	0	0	0	0	0	1
HardheidNaDC_transport#s3	4	4.5	0	0	0	1	0	0	0	0	0	0	0	0	0	1
HardheidNaDC_transport#s4	4.5	5	0	1	1	3	10	3	0	0	0	0	0	0	0	18
HardheidNaDC_transport#s5	5	5.5	0	0	0	1	7	20	11	0	1	0	0	0	0	40
HardheidNaDC_transport#s6	5.5	6	0	0	0	0	0	1	8	2	0	0	0	0	0	11
HardheidNaDC_transport#s7	6	6.5	0	0	0	0	0	0	0	0	0	0	0	0	0	0
HardheidNaDC_transport#s8	6.5	7	0	0	0	0	0	0	0	1	1	0	0	0	0	2
HardheidNaDC_transport#s9	7	7.5	0	0	0	0	0	0	0	0	0	0	0	0	0	0
HardheidNaDC_transport#s10	7.5	#DIV/0!	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Total			0	2	1	5	17	24	19	3	2	0	0	0	0	73

De groene vakken in beide tabellen laten de aantallen correcte exacte voorspellingen zien waarbij de 30%-set dezelfde voorspelling gedaan heeft als de 70%-set, in welke hardheidsklasse de betreffende partij het meest waarschijnlijk terecht komt. Het percentage gevallen waarvoor dat correct is gebeurd, de *performance voor deze factor*, is resp. 47% (33/70) en 55% (40/73) voor de eerste en tweede run van de tool.

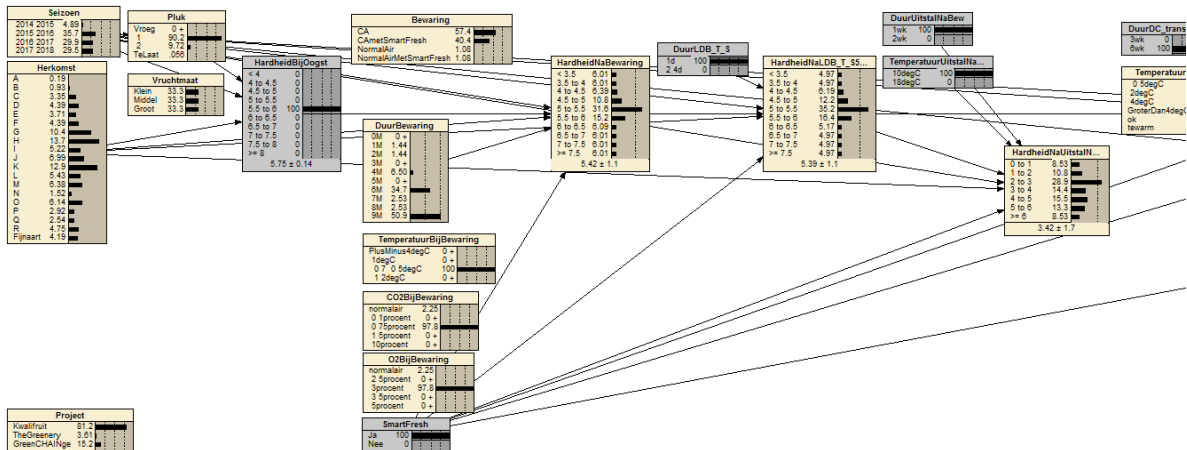
De blauwgekleurde getallen in beide tabellen laten de correcte voorspellingen van een hardheid groter dan 5, dan wel lager dan 5 zien. Deze voldoen dus aan de gevraagde splitsing van partijen, ondanks dat ze niet allemaal precies in de juiste klasse voorspeld zijn. Het percentage gevallen waarvoor dat correct is gebeurd, de *performance voor deze factor*, is respectievelijk 79 en 85% voor de eerste en tweede run van de tool. De performance van het model ligt voor de specifieke vraag dus veel hoger.

Deze validatie kunnen we ook voor andere factoren doen. De waarde van performance hangt af van welke voorspelling men van het model vraagt.

# 6 Modelgebruik

## 6.1 Voorspellingsscenario's en beslissingsondersteuning

De belangrijkste vorm van gebruik van het model, is het doorrekenen van scenario's. In onderstaande figuur is een screenshot van het model weergegeven op het moment van een scenariodoorrekening. Waarden van stochasten zijn aangeklikt (in grijs), op basis waarvan (direct of indirect) gerelateerde stochasten worden herberekend (dat wil zeggen de verschillende waarden van een stochast krijgen andere waarschijnlijkheden).



**Figuur 6. Voorbeeld van een scenariodoorrekening (Scenario 4) met het Bayesiaanse netwerk in Netica.**

We illustreren het gebruik van het model aan de hand van doorrekening van een aantal scenario's, waarbij we de volgende vragen centraal stellen:

**“Hoe groot is de kans dat een partij, van een bepaalde herkomst in bepaalde ketenomstandigheden, een gemiddelde hardheid heeft groter dan of gelijk aan 5, bij aankomst na ver transport. Wat is de verwachte gemiddelde hardheid van deze peren na een week uitstal bij 10°C?”**

In onderstaande tabel worden de factoren weergegeven die bewust aangeklikt worden (“feiten”). De overige factoren worden door het model zelf ingevuld op basis van alle aanwezige data in de datafile. In de gekozen scenario's maken we gebruik data betreffende alle seizoenen en bewaarduren.

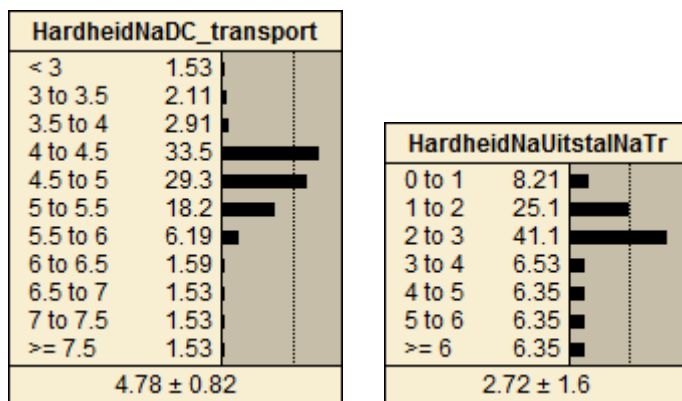
**Tabel 5. Scenario's.**

Factor	Scenario 1	Scenario 2	Scenario 3	Scenario 4	Scenario 5
Herkomst	<b>K</b>	<b>K</b>	<b>Geen keuze</b>	<b>Geen keuze</b>	<b>Geen keuze</b>
Pluktijdstip	<b>Geen keuze</b>	<b>Geen keuze</b>	<b>Geen keuze</b>	<b>Geen keuze</b>	<b>2</b>
Hardheid na oogst (gemeten)	5,5-6	5,5-6	5,5-6	5,5-6	5,5-6
SmartFresh	<b>Nee</b>	<b>Ja</b>	<b>Nee</b>	<b>Ja</b>	<b>Nee</b>
Duur ldbt (=transport/sortering na bewaring)	1 dag	1 dag	1 dag	1 dag	1 dag
Duur uitstal (na bewaring en na transport)	1 wk	1 wk	1 wk	1 wk	1 wk
Temperatuur uitstal (na bewaring en na transport)	10°C	10°C	10°C	10°C	10°C
Duur transport	6 wk	6 wk	6 wk	6 wk	6 wk
Temperatuur transport	-0,5°C	-0,5°C	-0,5°C	-0,5°C	-0,5°C

### Scenario 1: Specifieke herkomst, geen SmartFresh, geen pluktijdstip opgegeven

De uitkomst van doorrekening van scenario 1 is in figuur 7 gepresenteerd. De figuren tonen inzicht in de verwachte kansverdeling over de verschillende klassen. Het antwoord op bovenstaande vraag wordt verkregen door de percentages op te tellen van de klassen groter of gelijk aan 5. Het model voorspelt de kans dat deze partij met een hardheid > 5 aankomt na 6 weken transport op **30,6%**. De verwachte gemiddelde hardheid na uitstal na ver transport staat in de figuur rechts. De gemiddelde berekening komt uit op **2,72 kg**. Het grootst is de kans op een hardheid tussen 2 en 3 na uitstal.


De figuren tonen ook dat er kleine kansen zijn op extreme waarden: bijvoorbeeld na uitstal is de kans 6% op een hardheid > 6 kg. En dit is hetzelfde voor klasse 4-5 en 5-6. Dit zijn de zgn. "restklassen", die het gevolg zijn van missende data voor bepaalde combinaties van waarden van de inputvariabelen. Deze tellen echter wel mee in het berekende verwachte gemiddelde.



**Figuur 7. Uitkomst scenario 1 Kansen op verschillende gemiddelde hardheidsklassen na het verre transport (links) en na uitstal (rechts) en onderaan het totale verwachte batch gemiddelde met standaardafwijking.**

### Scenario 2: Invloed SmartFresh

In een tweede scenario willen we weten of de kans op succes verbetert als deze partij met deze hardheid bij oogst en dezelfde omstandigheden met SmartFresh zouden behandelen. We klikken SmartFresh "ja" aan. We krijgen dan de volgende resultaten:




**Figuur 8. Uitkomst scenario 2 Kansen op verschillende gemiddelde hardheidsklassen na het verre transport (links) en na uitstal (rechts) en onderaan het totale verwachte batch gemiddelde met standaardafwijking.**

De kans op succes stijgt naar op **52,5%**. Ook de gemiddelde verwachte hardheid na uitstal wordt hoger (**3,16 kg**). Toch blijft de grootste kans nog steeds dat het gemiddelde van de batch in categorie met hardheid 2-3 valt (invloed van restklassen).

### Scenario 3: Verschil tussen berekening specifieke herkomst of op basis van alle herkomsten

In scenario 3 laten we herkomst K los en kijken we naar de data betreffende alle herkomsten in het model, er wordt geen SmartFresh toegepast. Door herkomst K los te laten baseert het model zich op meer data, maar minder specifiek.



**Figuur 9. Uitkomst scenario 3 Kansen op verschillende gemiddelde hardheidsklassen na het verre transport (links) en na uitstal (rechts) en onderaan het totale verwachte batch gemiddelde met standaardafwijking.**


De kans op een hardheid na bewaring groter dan 5 is een stuk hoger dan als we fixeren op herkomst K: **46,4%**. Blijkbaar zijn er veel andere partijen met betere resultaten dan herkomst K.

De gemiddelde hardheid na uitstal verschilt minimaal: **2,63** (scenario 3) vs. 2,72 kg (scenario 1).

De kans is nog steeds het grootst dat de hardheid tussen 2 en 3 zal liggen.

### Scenario 4: Alle herkomsten en reactie op toepassing SmartFresh

In scenario 4 gaan we door op scenario 3 met data van alle herkomsten, maar nu uitgaande van toepassing van SmartFresh.




**Figuur 10. Uitkomst scenario 4 Kansen op verschillende gemiddelde hardheidsklassen na het verre transport (links) en na uitstal (rechts) en onderaan het totale verwachte batch gemiddelde met standaardafwijking.**

De kans op de gewenste hardheid is nu verhoogd tot **58,1%**. De gemiddelde hardheid na uitstal ligt iets hoger dan we tot dusverre gezien hebben, op **3,29 kg**. De meeste partijen zullen na uitstal nog een hardheid tussen 2 en 3 hebben, maar er is nu ook een hogere kans op hardheid tussen 3-4 en 4-5.

### Scenario 5: Invloed van later pluktijdstip

Nu gaan we alleen een wat later pluktijdstip selecteren om te kijken hoe sterk het effect hiervan is op succes (fixeren pluk 2, SmartFresh nee).



**Figuur 11. Uitkomst scenario 5 Kansen op verschillende gemiddelde hardheidsklassen na het verre transport (links) en na uitstal (rechts) en onderaan het totale verwachte batch gemiddelde met standaardafwijking.**

De kans op hardheid groter dan 5 is gedaald tot **41,0%** (vs. 46,6% scenario 3). De gemiddelde hardheid na uitstal ligt op het laagste niveau van alle scenarioberekeningen tot nu toe: de gemiddelde berekening komt uit op **2,72 kg**. De kans is nu bovendien het grootst dat de hardheid tussen 1 en 2 zal komen te liggen.

Het samengevatte resultaat van de kans dat de hardheid na ver transport van de partij in een klasse >5 valt en de verwachte gemiddelde hardheid na uitstal is in tabel 6 weergegeven:

**Tabel 6. Resultaten scenario's.**

Factor	Scenario 1	Scenario 2	Scenario 3	Scenario 4	Scenario 5
Kans hardheid ≥ 5	30,6%	52,5%	46,4%	58,1%	41%
Gem. hardheid na uitstal	2,72	3,16	2,63	3,29	2,49

Er kunnen op deze manier eindeloos veel scenario's doorgerekend worden. Wat we van bovenstaande berekeningen inhoudelijk leren is dat:

- De kansen op succes (hardheid > 5 bij aankomst na transport) niet heel groot zijn op basis van deze scenarioberekeningen (30-58%).
- SmartFresh verhoogt de kans op succes aanzienlijk (naar 52,5% en 58%).  
Herkomst K en/of een laat pluktijdstip verlagen de kansen ten opzichte van andere herkomsten en een vroeger pluktijdstip.

## 6.2 Gevoeligheidsanalyse

Een ander gebruik van een Bayesiaans netwerk is het uitvoeren van gevoeligheidsanalyses om meer kennis op te bouwen over de invloed van verschillende variabelen en hun relaties. Hieronder tonen we de resultaten voor twee gevoeligheidsanalyses: een voor hardheid na DC/transport en een voor hardheid na uitstal na transport.



**Tabel 7. Resultaten gevoeligheidsanalyse van hardheid na DC/transport voor andere variabelen in het model. Variabelen waar de gevoeligheid 0 voor is, zijn niet opgenomen in de tabel.**

Node	Percentage mogelijke invloed
HardheidNaLokaalTranspor	14,1
HardheidNaLDB_T_S5degC	3,7
HardheidNaUitstalNaTr	1.93
HardheidNaBewaring	1.7
Seizoen	1.69
HardheidBijOogst	1.09
HardheidNaUitstalNaBew	0,734
Herkomst	0,377
SmartFresh	0,163
Pluk	0,109
DuurBewaring	0,052
TemperatuurDC_transport	0,0125
DuurLDB_T_S	0,00731
DuurDC_transport	0,00183

**Tabel 8. Resultaten gevoeligheidsanalyse van hardheid na uitstal na DC/transport voor andere variabelen in het model. Variabelen waar de gevoeligheid 0 voor is, zijn niet opgenomen in de tabel.**

Node	Percentage mogelijke invloed
Seizoen	9,37
HardheidNaLokaalTransport	7,25
SmartFresh	6,5
HardheidNaDC_transport	4,33
HardheidNaUitstalNaBew	1.83
HardheidNaLDB_T_S5degC	1.81
HardheidNaBewaring	1.37
HardheidBijOogst	1.07
Pluk	0,288
TemperatuurUitstalNaTr	0,0572
Herkomst	0,0559
DuurBewaring	0,0406
TemperatuurDC_transport	0,0127
DuurLDB_T_S	0,00363
DuurDC_transport	0,00119

In de tabel na DC/transport zien we dat de betreffende hardheid van andere hardheden (op andere tijdstippen) afhangt. Dat is logisch, want een hardheid op een bepaald moment, zal op een volgend moment niet in één keer een totaal andere waarde hebben. In de tabel van de hardheid na uitstal na transport is dit minder het geval. Hier blijken factoren als seizoen en wel of geen toepassing van SmartFresh duidelijk van invloed te zijn. Factoren als pluk, herkomst, duur bewaring komen als minder invloedrijk uit de analyse. Het resultaat wordt beïnvloed door hoeveelheid data (bijvoorbeeld de resultaten voor duren en temperaturen van bewaring en transport, hiervan weten we dat de datafile slechts weinig verschillende waarden bevat).

---

## 6.3 End user interface

Het model zoals we het tot dusverre hebben laten zien en behandeld in dit rapport zal nooit op deze wijze door de eindgebruiker gebruikt worden. Er zal een gebruikersvriendelijke schil omheen moeten die met het model communiceert. Het softwarepakket waarin het model is gebouwd, Netica, staat dit toe, middels diens Application Programming Interface (API).

Een eerste schets die we gemaakt hebben van een beoogde user interface, op basis van de centrale vraag die we onszelf gesteld hebben in de scenario analyse, geven we hieronder. Deze schets is het resultaat van een aantal iteraties, binnen het team en met een mogelijke eindgebruiker.

Het draait in deze user interface om de volgende vragen:


**“Heeft partij X voldoende kans om met een gewenste hardheid aan te komen op bestemming, bij bepaalde ketencondities?”**

Het eerste gedeelte is een onderdeel waarin de gebruiker zijn eindkwaliteitswens kan formuleren op basis van een bepaalde verwachte of beoogde condities tijdens bewaring en transport. Hij geeft per kwaliteitsvariabele (nu hardheid, maar in de toekomst kunnen nog andere kwaliteitsvariabelen zoals interne bruinverkleuring, rot, kleur etc. worden meegenomen in de modellering) de gewenste minimale gemiddelde waarde van de partij en de kans die nog geaccepteerd wordt (in groen aangegeven) en de kans waarop het risico onacceptabel is (in rood aangegeven). Er kan aangegeven worden of de partij behandeld is/wordt met SmartFresh. De bewaar/transportcondities vallen uiteen in duur, temperatuur.

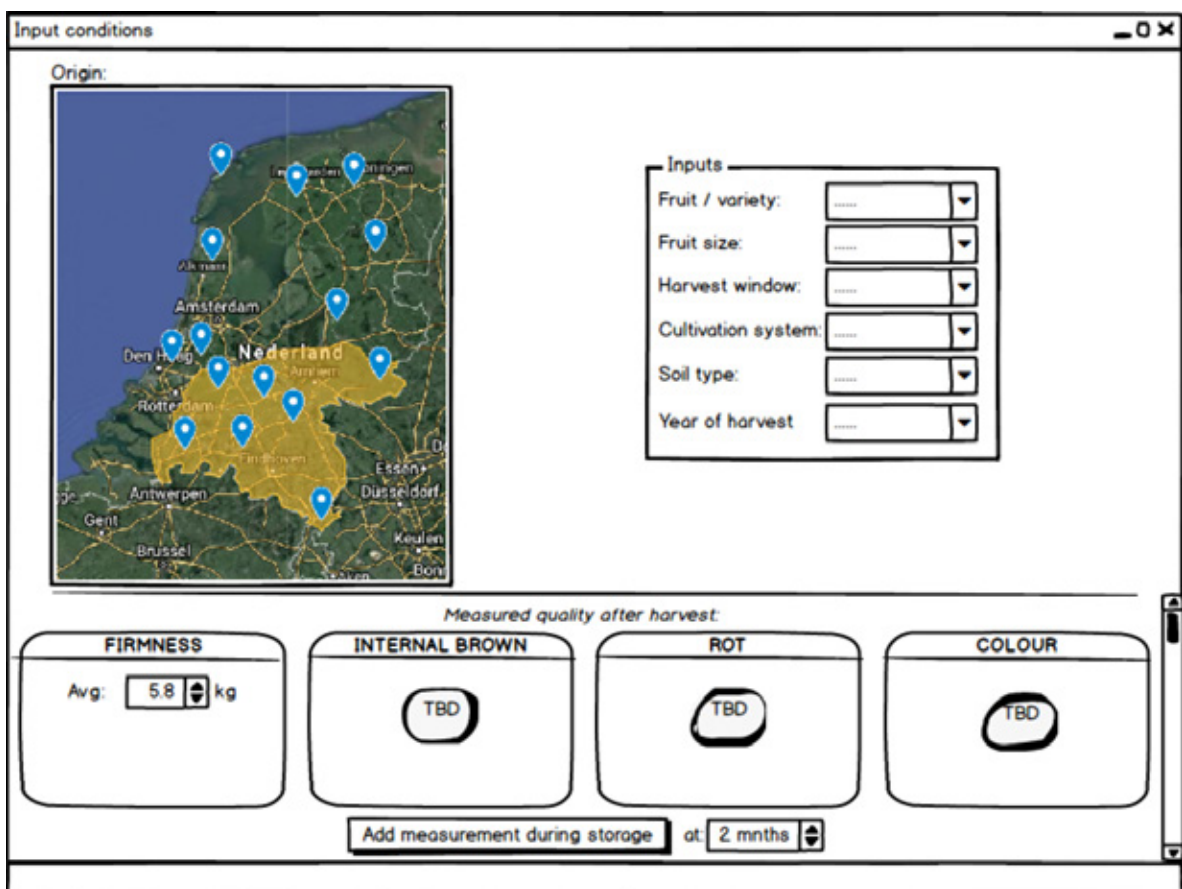
Daarna volgt een gedeelte waarbij de feitelijke situatie beschreven wordt, als deze bekend is: herkomst van het product, alsmede eigenschappen zoals ras, pluk, en andere teelteigenschappen. Daaronder de eventuele resultaten van kwaliteitsmetingen bij inslag (gemiddelde waarden), en eventueel tijdens bewaring, mochten deze bekend zijn.

Het laatste onderdeel betreft de uitkomst: de berekening van de kans op een verwachte kwaliteit wordt aangegeven en met een kleur (stoplicht) wordt aangegeven of dat de kans binnen de acceptatie-/risicogrenzen valt zoals in eerste screenshot (figuur 12) wordt gespecificeerd. Daarnaast worden ook de gemiddelde waarden van de hardheden na bewaring en uitstal (deze laatste bij een bepaalde duur en temperatuur) gegeven. Het aantal datapunten waarop de voorspellingen zijn gebaseerd, hebben we hier ook aangegeven, dit kan bijdragen in een oordeel of de voorspelling op voldoende of te weinig datarecords gebaseerd is. Het is moeilijk in algemene zin aan te geven *wanneer* sprake is van een te laag aantal datapunten, hier wordt in hoofdstuk 7 nog verder op ingegaan.


De schetsen zijn slechts een voorbeeld hoe het model in een wat visueel aantrekkelijker en simpeler format te gieten is en hoe het bruikbaar gemaakt kan worden voor een specifieke gebruiker.



**Figuur 12. Schets van de user interface (1). Wens kwaliteit, bewaarduur en transportgegevens kunnen worden aangegeven.**



**Figuur 13. Schets van de user interface (2). Inputgegevens (variabelen en meetgegevens) kunnen worden opgegeven.**



Figuur 14. Schets van de user interface (3). Verwachte kwaliteit wordt voorspeld.

---

## 7 Conclusies & discussie

In hoofdstuk 1 hebben we vier doelen beschreven, die we hebben beoogd met het ontwikkelen van het Bayesiaanse netwerk voor peren. We kunnen concluderen dat het ontwikkelde Bayesiaanse netwerk kansen op verschillende gemiddelde hardheden van partijen kan voorspellen, op verschillende punten in een (verre-bestemmingen) keten. De uitkomsten van de scenarioanalyse in hoofdstuk 6 illustreren dit. We hebben de kwaliteit van de voorspellingen gecheckt door naar de hardheidsontwikkeling in de keten te kijken vanaf een initiële hardheid van 5-6. De validatie toonde met 80 % een goede performance index: In 80% van de voorspellingen een juist antwoord op de vraag of een partij met een gemiddelde hardheid  $> 5$  aankomt op bestemming. Het model is een basis voor uitbreiding op andere kwaliteitsfactoren of condities en voor aanvulling met data uit de praktijk. De voorbeeldschets van de user interface geeft een voorbeeld hoe het model naar een praktijktoepassing vertaald kan worden en aan welke uitbreidingen gedacht kan worden.

In de volgende paragrafen noemen we per doel een aantal aandachtspunten voor succesvol gebruik of verdere ontwikkeling van het model.

### 7.1 Geschiktheid model voor kwaliteitsvoorspelling

#### 7.1.1 Scope model en dataset


De huidige scope en de dataset van dit model geven bepaalde beperkingen aan de huidige mogelijkheden en betrouwbaarheid van het model. We hebben op dit moment weinig extreme waarden in de data. Voor sommige van deze waarden zijn expertregels gevormd (hogere temperatuur tijdens transport) maar deze zijn niet met data geverifieerd. Ook zijn er van bepaalde variabelen slechts beperkte variaties opgenomen in de dataset (bijvoorbeeld bewaarduur/condities), omdat veel van de data van projecten afkomstig is waarin partijen op eenzelfde manier bewaard werden. Ook de toepassing van SmartFresh is vaak tegelijk op meerdere partijen uitgevoerd, en niet allemaal afzonderlijk. Om de voorspelling te verbeteren is het belangrijk om het model met meer praktijkdata aan te vullen om zo meer variatie in omstandigheden te krijgen.

De voorspelling van het model op dit moment geeft als output de kans dat de gemiddelde hardheid van een partij in een bepaalde (hardheids)klasse valt op een bepaald moment. Het berekende gemiddelde, dat gegeven wordt voor een stochast, is echter *niet* het verwachte gemiddelde van de partij, maar het verwachte gemiddelde als er veel van dit soort partijen verstuurd zouden worden. Deze gemiddelden kunnen gelijk zijn aan elkaar, als we met een normaalverdeling te maken hebben. Echter, ze verschillen van elkaar als de verdeling scheef is over de klassen (met bijvoorbeeld een staart of schouders) en bij weinig data, waardoor zgn. "restklassen" (de uiterste lage en hoge klassen, waar in het algemeen weinig data voor beschikbaar zijn) relatief sterk meetellen. Die klassen krijgen namelijk, bij missende waarden van de variabelen waar de betreffende variabele van afhankelijk is, een (overall kleine) waarschijnlijkheid, die bij cumulatie (van die restklassen) echter wel kan meetellen. Met de "gemiddelde" berekeningen van de variabelen moet dus, evenals in zijn algemeenheid, voorzichtig worden omgegaan in de interpretatie.

Aanbevolen wordt voor het huidige model om de zgn. restklassen van de verschillende variabelen nogmaals te beschouwen. Sommigen kunnen dus wellicht nog verwijderd worden. Klassen die juist vaak voorkomen kunnen misschien nog fijner worden gedefinieerd. In dat geval wordt wel afgestapt van de huidige lineaire schalen die voor de mens gemakkelijk interpreteerbaar zijn. Het grote voordeel van het aanpassen van de klassen op de mate van voorkomen van de betreffende data is dat de klassen die minder frequent voorkomen minder invloed zullen uitoefenen op de gemiddeldeberekening bij afwezigheid van data. In dat geval worden namelijk uniforme verdelingen aangenomen door de software die in feite per definitie weinig (of minder) realistisch zijn.

### 7.1.2 Hoeveelheid en kwaliteit data

Een belangrijk aandachtspunt bij Bayesiaanse netwerken in het algemeen, maar ook voor dit huidige Bayesiaanse netwerk is de *kwaliteit en de hoeveelheid* data waarop een voorspelling wordt gebaseerd. Data moet zo veel mogelijk op een standaardmanier verzameld zijn (standaard meetapparatuur, gecalibreerd, etc.). Het hebben van weinig data herken je in Netica als je bijvoorbeeld bepaalde waarden van stochasten in het model aanklikt om te zien wat de invloed is van die specifieke waarden. Je ziet dat dan de hoeveelheid data waarop die afhankelijkheden zijn gebaseerd, beperkt wordt. Als je dan ook nog andere waarden (van andere variabelen) aanklikt dan kan het zijn dat het resultaat in een stochast op slechts enkele records gebaseerd wordt (if any). Een behoorlijk grove verdeling (wijd verdeeld over alle klassen) in de betreffende variabele is daar vaak een aanwijzing voor (zie Figuur 15). Als er helemaal geen data onderliggend is aan een bepaald scenario (combinatie van specifieke waarden van factoren), laat het Bayesiaanse netwerk een volledig uniforme verdeling zien. Die is dus in zijn geheel niet gebaseerd op data, maar is de default-distributie als je helemaal niets weet (dan krijgt iedere waarde een even grote kans, wat leidt tot een uniforme verdeling). Het zou waardevol kunnen zijn dat de aantallen records waarop een uitspraak gebaseerd is weergegeven worden met eventueel een soort waarschuwing, als er sprake is van te weinig data. Beide worden op dit moment niet ondersteund door het gebruikte softwarepakket.



**Figuur 15. Grove verdeling van hardheid na bewaring die ontstaat als herkomst, seizoen, en pluk een specifieke waarde krijgen.**

Echter, hoe kan je beoordelen of je genoeg data hebt voor een betrouwbare berekening/uitkomst of gevoeligheidsanalyse? Op basis van hoeveel onderliggende data verkrijgen we een significant verantwoorde uitspraak op het scenario dat je kiest? De huidige validatietool geeft een goede eerste indicatie van betrouwbaarheid, maar is niet alleszeggend. Het zegt niets over of je dataset voldoende overweg kan met extremere scenario's. Ook als de output van een variabele niet normaal verdeeld is, is het lastig om dan een goede performance op te krijgen (en ook de voorspelling van verwachte gemiddelde hardheid klopt dan niet). En sowieso zullen er van extreme waarden vaak weinig data voorhanden zijn omdat dit niet vaak voorkomt. Dit heeft ook gevolgen voor variabelen die afhankelijk zijn van die variabelen: een eventueel grote hoeveelheid data "van" de afhankelijk variabele wordt dan alsnog ingeperkt door die onafhankelijke. Het toevoegen van een expertregel kan in zo'n geval een beter resultaat geven dan het laten baseren op een klein aantal datarecords. Het kan zinvol zijn om expertregels middels experimenten te toetsen/onderbouwen. In het algemeen is een Bayesiaans netwerk gebaat bij zowel data als aanvullende expertregels.

### 7.1.3 Validatie

In Hst. 5.2 beschrijven we twee manieren om de performance te berekenen van een Bayesiaans netwerk door middel van een validatietool. Beide manieren variëren in strengheid. De manier waarbij alleen de precieze juiste voorspelling meegenomen wordt is relatief streng en dat betekent niet altijd beter. Doordat er gewerkt wordt met klassen kan een voorspelling die net op of net onder een bepaalde klasse valt relatief zwaar "fout" meetellen, terwijl je in werkelijkheid er maar net naast zit. Als we checken of het model de juiste splitsing maakt tussen kans op hardheid > 5 of < 5 gaat de performance sterk omhoog (het model is zekerder van zijn voorspelling van de kans). Dit is een "makkelijkere" maar minder precieze vraag, maar kan voor het doel voldoende zijn.

---

De huidige berekende performance middels de validatietool geeft een maat voor de robuustheid/voorspelbaarheid van de huidige dataset. Het legt namelijk telkens verschillende versies van het model naast elkaar, die gebaseerd zijn op dezelfde data. Een hoge performance wil dus nog niet zeggen dat dit goed overeenkomt met de werkelijkheid. Dat hangt af van hoe goed de data de werkelijkheid representeert.

Een alternatief voor performance is werken met de gemiddelde afwijking van een variabele. Je kijkt dan niet meer of precies de juiste klasse voorspeld wordt, maar hoeveel – per (validatie)record – de voorspelde gemiddelde waarde afwijkt van de (in dat record) gemeten waarde. Het verschil daartussen is de afwijking, en over meerdere records kunnen we die weer middelen. Deze waarde is alleen relevant als sprake is van verdelingen waarbij het gemiddelde voorspellende waarde heeft, zoals een normale verdeling. De gemiddelde afwijking kan enerzijds iets over de spreiding van de data en anderzijds iets over modelkwaliteit zeggen. Deze twee zaken zijn moeilijk uit elkaar te halen en daardoor is de gemiddelde afwijking geen absolute maat voor modelkwaliteit. Je zou eerst de spreiding in de gemeten data moeten bepalen en deze moeten verrekenen met de gemiddelde afwijking (voor een bepaalde variabele in het model). Zonder deze actie kan de gemiddelde afwijking eigenlijk alleen worden gebruikt om verschillende *versies* van modellen met elkaar te vergelijken. In de toekomst is het denkbaar dat we gaan werken met meerdere versies van het model om specifieke hypothesen (met betrekking tot afhankelijkheden van kwaliteit) te toetsen.

Uitbreiding met data (bij dezelfde omstandigheden als ook meer combinaties van specifieke omstandigheden) zal normaal gesproken de performance verhogen en beter aansluiten met de werkelijkheid. Echter als er een nieuw, onbegrepen proces speelt in je keten, dan kan een lagere performance een signaal zijn dat er ergens iets aan de hand is in de keten.

## 7.2 Kansen voor uitbreiding en toepassing van het model

Er zijn veel uitbreidingen mogelijk op de huidige “basisstructuur”. Zoals aangegeven kan er gekeken worden in de richting van meer data over bijvoorbeeld bewaarduur, bewaaromstandigheden, teeltomstandigheden, SmartFresh-behandelingen, nieuwe seizoenen, regio, etc. Ook kan het model uitgebreid worden met andere rassen dan Conference. Een andere richting is om andere kwaliteitsfactoren in het model op te nemen. Op dit moment wordt alleen hardheid beschreven; in de toekomst kan uitgebreid worden met intern bruin, rot, kleur, en slappe nekken. Zie ook de voorbeeld-user-interface (paragraaf 6.3), voor ideeën hoe het model uitgebreid kan worden. Uitkomsten van gevoeligheidsanalyse en scenarioberekeningen geven aanwijzingen om een bepaald onderwerp verder uit te diepen, bijvoorbeeld invloed van het seizoen of SmartFresh.

Omdat de structuur van het model (invloed van condities op meerdere kwaliteitsfactoren over de tijd) generiek is, kan in de toekomst uitgebreid worden naar andere vruchten met andere kwaliteitsfactoren. Het belangrijkste criterium is dat er data/expertkennis betreffende de genoemde zaken beschikbaar is; de standaardaanpak met condities die invloed hebben op kwaliteitsvariabelen die in een keten aan elkaar gelinkt zijn, is dan opnieuw toepasbaar. De beoordeling van beschikbare data en geschiktheid voor het maken/uitbreiden van het model is een belangrijke stap voordat er daadwerkelijk uitgebreid/aangepast gaat worden.

Het model kan toegepast worden binnen de (bestaande) IT-infrastructuur van een teler. Door koppeling met (nieuwe) data, kan het model steeds meer leren, bijvoorbeeld over ieder nieuw seizoen. Als dit automatisch plaatsvindt dan wordt dit zelflerend genoemd. Berekeningen van scenario's veranderen dan continu op basis van nieuwe data/feiten. Het inpassen van een Bayesiaans netwerk in bestaande IT-infrastructuur is net als voor iedere externe module echter wel een activiteit waar de nodige resources tegenaan gezet moeten worden.

---

## 7.3 Voordelen Bayesiaans netwerk ten opzichte van andere modellen

Het grote voordeel van een Bayesiaans netwerk ten opzichte van andere probabilistische (voorspellende) modellen is dat er verschillende soorten databronnen gecombineerd kunnen worden: experimentele data, praktijkdata, partiële data, expertkennis, rekenregels, formules. Geen van deze bronnen hoeft volledig te zijn om gebruikt te kunnen worden voor een voorspelling.

De toegevoegde waarde van een Bayesiaans netwerk zit hem ook in het grafische aspect: op een heldere manier worden de relaties en de data (door middel van de verdelingen, de "balkjes") gevisualiseerd, wat de kennis transparant en daarmee bediscussieerbaar maakt. Ook het kunnen "aanklikken" van een bepaalde waarde en de veranderingen kunnen zien is heel sterk. Het komt tegemoet of overeen met intuïtief denken, maar het kan veel complexere relatienetwerken aan dan de mens dat kan.

Bovendien is het de enige modelleertechniek die toestaat dat je iets transparant (whitebox) modelleert, zonder dat je over formules beschikt. De techniek blijft eigenlijk heel dicht bij de data. Of bij de expertinschattingen, want ook dat is een sterk punt: expertkennis kan, gefundeerd in de data, worden toegevoegd aan het model. Zelfs formules kunnen worden toegevoegd aan de variabelen waarvoor die bekend zijn. Daarmee is het een van de weinige technieken waarin discrete data gecombineerd kunnen worden met continue formules.

Een Bayesiaans netwerk doet in feite niets anders dan tellen. Toch is het een techniek die niet zomaar beschikbaar is in statistische pakketten of spreadsheetprogramma's. Het is te ingewikkeld om het soort tellingen zelf uit te voeren in dit soort tools. Dit onderstreept ook de relevantie van de techniek.

## 7.4 Inzichten op basis van het huidige model

Een laatste doel van het opzetten van dit model is het vinden van nieuwe inzichten over kwaliteit/hardheidsverloop van Conference-peren in een verre-bestemmingenketen. De resultaten uit de scenarioanalyses (hoofdstuk 6.1) tonen onder andere dat de kansen op succes (hardheid > 5 bij aankomst na transport) 30-58% zijn op basis van deze scenarioberekeningen. Toepassing van SmartFresh geeft wel een sterke verbetering (meer dan 50% kans op succes mogelijk) en een latere pluk verlaagt de kans op succes. Veel andere scenario's zijn nog op weinig datarecords gebaseerd, en moeten voorzichtiger geïnterpreteerd worden.

Uit de gevoeligheidsanalyse (op basis van de huidige datafile) blijkt dat een eerder gemeten gemiddelde hardheid van een partij op dit moment de invloedrijkste factor is voor een latere hardheid. Dit is bepalender dan herkomst, of pluk, of het feit of een partij met SmartFresh behandeld is. Daarentegen, de gemiddelde hardheid na uitstal wordt wel sterk beïnvloed door seizoen en ook door het gebruik van SmartFresh. Herkomst en pluktijdstip blijken als factor slechts weinig invloed te hebben op hardheid na uitstal. Dit inzicht is een bevestiging van de bevindingen na analyse van data in Kwalifruit. Met gangbare methoden zou het moeilijker worden om deze invloeden te bepalen, maar door middel van een Bayesiaans netwerk is dit wel mogelijk.





To explore  
the potential  
of nature to  
improve the  
quality of life



Wageningen Food & Biobased Research  
Bornse Weilanden 9  
6708 WG Wageningen  
[www.wur.nl/wfbr](http://www.wur.nl/wfbr)  
[info.wfbr@wur.nl](mailto:info.wfbr@wur.nl)

Rapport 1877  
ISBN 978-94-6343-553-6

De missie van Wageningen University & Research is 'To explore the potential of nature to improve the quality of life'. Binnen Wageningen University & Research bundelen Wageningen University en gespecialiseerde onderzoeksinstituten van Stichting Wageningen Research hun krachten om bij te dragen aan de oplossing van belangrijke vragen in het domein van gezonde voeding en leefomgeving. Met ongeveer 30 vestigingen, 5.000 medewerkers en 10.000 studenten behoort Wageningen University & Research wereldwijd tot de aansprekende kennisinstellingen binnen haar domein. De integrale benadering van de vraagstukken en de samenwerking tussen verschillende disciplines vormen het hart van de unieke Wageningen aanpak.

