

Inleiding

Kwalitatieve gegevens

- Ordinaal *tellen, ordenen*
- Nominaal *categorieën, niet-numerieke schaal*

Kwantitatieve gegevens

- Continue (*oneindig en niet aftelbaar*) vs discreet (*eindig en aftelbaar*)
- Intervalschaal (*zelf gekozen nulpunt*) vs ratioschaal (*natuurlijk nulpunt*)

Beschrijvende statistiek

Voorstellen gegeven

- **Univariate kwalitatieve gegevens**
 - Absolute en relatieve frequentie
 - Staafdiagram
 - Taartdiagram
 - Paretdiagram *ordenen volgens dalende frequentie*
- **Univariate kwantitatieve gegevens**
 - Stengel – en blad diagram
 - Histogram
 - Polygoon *hoogste punten van het histogram met elkaar verbinden*
- **Bivariate gegevens**
 - Kruistabel of meervoudig staafdiagram
 - Stapeldiagram
 - Scatterwolk (puntenwolk)

Cumulatieve frequenties

Enkel bij kwantitatieve gegevens

- **Cumulatieve verdelingsfunctie**
 - $F_n(x)$ = aantal waarnemingen/ n
 - = cumulatieve relatieve frequentie
 - Trapfunctie
- **Kwantielfunctie**
 - = inverse van de cumulatieve verdelingsfunctie
 - $Q_n(p) = \inf \{ x \in \mathbb{R} \mid F_n(x) > p \}$ met $0 < p < 1$
 - $Q_n(p) = x_i$ met $i = \lceil np \rceil$ (= afronden naar boven)
 - Trapfunctie

Centrum kenmerken

- **Gemiddelde**
- $\bar{x} = \frac{1}{n} \sum x_i$
 - De gewogen som is dat sommige variabelen maar een aantal mogelijke waarden kunnen aannemen.
 - $\bar{x} = \frac{1}{n} \sum x_i m$
 - Som van de gecentreerde gegevens is steeds 0
 - $\sum (x_i - \bar{x}) = 0$
- **Getrimd gemiddelde**
 - Het gemiddelde van gegevens waarbij een aantal van de kleinste en grootste gegevens zijn weggelaten. Sorteren van klein naar groot!

➤ **Mediaan**

- $\text{Med}(x) = x_{((n+1)/2)}$ als n oneven is
- $\text{Med}(x) = (x_{(n/2)} + x_{(n/2+1)})/2$

➤ **Modus**

- Is het element dat het meeste voorkomt, dus de hoogste frequentie heeft

Spreidingskenmerken

➤ **Variantie en standaardafwijking**

- $\text{Var}(x) = s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$
- Door het kwadraat vermijden we dat positieve en negatieve afwijkingen elkaar aflossen
- Grote spreiding = grote variantie
- Standaardsteekproefafwijking: $s = \sqrt{S^2}$
- Eigenschap
 - $\text{Var}(y) = a^2 \text{var}(x)$
- Standaardisatie = z-score
 - $z_i = \frac{x_i - \bar{x}}{s}$

➤ **Variatiecoëfficiënt**

- Standaardafwijking/ absolute waarde van steekproefgemiddelde
 - $c_v = \frac{s_x}{|\bar{x}|}$
- Dimensie loze maat voor relatieve spreiding

➤ **Spreidingsbreedte**

- Of bereik is het verschil tussen de grootste en kleinste waarneming
- Gevoelig voor uitschieters

➤ **Interkwartiel afstand**

- Is de lengte van het gebied rond de mediaan dat ongeveer de helft van de gegevens bevat en wordt gedefinieerd adhv kwartielen
- Verdelen steekproef netjes in 4 delen
- $Q_1 = Q_n(0,25)$, $Q_3 = Q_n(0,75)$ en de mediaan vormt het tweede kwantiel
- $\text{IQR} = Q_3 - Q_1$

Boxplot

- Box is van 1^{ste} kwartiel tem 3^e kwartiel → bevat 50% van de gegevens
- Mediaan wordt weergegeven door horizontale lijn in de box
- Snorharen: de eerste reikt tot kleinste waarneming en de andere vanaf Q_3 tot de grootste waarneming. Deze kleinste en grootste waarnemers mogen geen

Empirische momenten

Zijn \bar{x} en var verheven tot een bepaalde macht

- Empirische k-de orde moment
 - $m_k = \frac{1}{n} \sum_{i=1}^n x_i^k$
- Empirische k-de orde **centrale** moment
 - $m_k = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^k$
- Empirische scheefheid
 - $\hat{\gamma} = \frac{m'_3}{(m'_2)^{3/2}}$
 - Hoe asymmetrisch is de steekproef
- Empirische kurtosis
 - $\hat{\kappa} = \frac{m'_4}{(m'_2)^2}$
 - Hoe dik zijn de staarten van de steekproef

Verband tussen 2 variabelen

- **Covariantie**
 - Meet de lineaire associatie
 - $cov(x, y) = s_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$
 - Hier kunnen de termen zowel positief als negatief zijn
 - Positieve associatie vinden we rechtsboven en linksonder
 - Negatieve associatie vinden we linksboven en rechtsonder
 - Positieve associatie lijdt tot een positieve covariantie
 - Eigenschap: $cov(a_1x + b_1, a_2x + b_2) = a_1a_2cov(x, y)$
- **Correlatie**
 - Helpt besluiten hoe sterk of zwak de associatie is
 - $r(x, y) = \frac{cov(x, y)}{\sqrt{var(x)}\sqrt{var(y)}} = \frac{1}{n-1} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{s_x} \right) \left(\frac{y_i - \bar{y}}{s_y} \right)$
 - Eigenschap: $r(a_1x + b_1, a_2x + b_2) = \text{teken}(a_1a_2)r(x, y)$
- **Lineaire regressie**
 - Is om het verband tussen twee variabelen grafisch voor te stellen
 - Zie cursus pag 28 tem 30

Kansrekening

Kans experimenten en uitkomstenruimte

- Elke deelverzameling van de uitkomstenruimte noemen een gebeurtenis
- Soorten gebeurtenissen
 - Elementaire gebeurt. *Deelverzameling met 1 element*
 - Zekere gebeurt. *Uitkomstenruimte*
 - Onmogelijke gebeurt. *Lege verzameling*
- Begrippen
 - Complementaire gebeurtenis
 - $A^c = \Omega \setminus A$
 - Vereniging of unie
 - $A \cup B$
 - Het treedt of in A of in B
 - Exhaustief
 - Indien de unie de volledige uitkomstenruimte is
 - Doorsnede
 - $A \cap B$
 - Het element zit in A EN in B
 - Disjunct
 - Indien de doorsnede van 2 verzamelingen leeg is

Kansfunctie

Axioma's van de kansrekening

- $P(A) \geq 0$, voor elke gebeurtenis A
- $P(\Omega) = 1$
- Voor elke rij disjuncte gebeurtenissen: $P(A_1 \cup A_2 \cup \dots) = P(A_1) + P(A_2) + \dots$

De empirische definitie:

Als een experimenten een groot aantal keer herhaald wordt, dan zal volgens de wet van de grote aantallen de relatieve frequentie van een gebeurtenis A zich stabiliseren rond de kans op die gebeurtenis.

Kans definitie van Laplace

De definitie gaat uit van een symmetrisch experiment, d.i. een experiment met een eindig aantal mogelijke uitkomsten die alle even waarschijnlijk zijn.

$$P(A) = \frac{\#A}{\#\Omega} = \frac{\text{gunstige uitkomsten}}{\text{mogelijke uitkomsten}}$$

Eigenschappen kansen

➤ $P(\emptyset) = 0$ dit volgt uit AX 3 en $\emptyset = \emptyset \cup \emptyset \cup \dots$

Omschrijving	Symbolen	Bewijs/verantwoord.
Unie van een eindig aantal disjuncte gebeurtenissen	$P(A_1 \cup A_2 \cup \dots \cup A_n)$ $= P(A_1 \cup A_2 \cup \dots)$ $= \sum_{i=1}^{\infty} P(A_i)$ $= \sum_{i=1}^n P(A_i)$	
Kans van de complementaire gebeurtenis	$P(A^c) = 1 - P(A)$	$1 = P(\Omega)$ $= P(A \cup A^c)$ $= P(A) + P(A^c)$
Grenzen van de kansfunctie	$0 \leq P(A) \leq 1$	Uit ax 1
Deelverzamelingen en kansen	Als A B impliceert maw $A \subseteq B$ dan is $P(A) \leq P(B)$ en $P(B \setminus A) = P(B) - P(A)$	
Optelregel	$P(A \cup B)$ $= P(A) + P(B) - P(A \cap B)$	$P(A \cup B)$ $= P(A \cup (B \setminus (A \cap B)))$ $= P(A) + P(B \setminus (A \cap B))$ $= P(A) + P(B) - P(A \cap B)$
Ongelijkheid van Boole	$P(A \cup B) \leq P(A) + P(B)$	Omdat $P(A \cap B)$ steeds positief is

Combinatorische kansrekening

➤ Productregel

- Alle mogelijke opties maal elkaar

➤ Variatie

- Is een **geordende** keuze van k objecten uit een taal van n verschillende objecten **zonder** teruglegging van de gekozen objecten
- Volgorde van de objecten speelt een rol
- $V_n^k = n(n-1)(n-2) \dots (n-k+1) = \frac{n!}{(n-k)!}$ GRT: $n \text{ nPR } k$
- Bv kiezen van een raad van bestuur

➤ Herhalingsvariatie

- Is een **geordende** keuze van k objecten uit een totaal van n verschillende objecten **met** teruglegging van de gekozen objecten
- Volgorde van de objecten speelt een rol
- $\overline{V}_n^k = n^k$

➤ Permutatie

- Is een variatie van n uit n
- Alle objecten worden gekozen → zien als herschikking
- $P_n = V_n^n = n(n-1)(n-2) \dots 1 = n!$

➤ Herhalingspermutatie

- Gebruiken we indien niet alle object
- $P_n = \frac{n!}{n_1!n_2! \dots n_m!}$
- Bv een anagram

➤ Combinatie

- Is een **ongeordende** keuze van k objecten uit een totaal van n verschillende objecten **zonder** teruglegging van de gekozen objecten
- Volgorde van de gekozen objecten speelt geen rol
- $C_n^k = \frac{V_n^k}{k!} = \frac{n!}{(n-k)!k!} = \binom{n}{k}$ GRT: $n \text{ nCr } k$
- Bv: lotto

➤ Herhalingscombinatie

- Is een **ongeordende** keuze van k objecten uit een totaal van n verschillende objecten **met** teruglegging van de gekozen objecten
- Volgorde van de gekozen objecten speelt geen rol
- $C_{k+n-1}^{n-1} = \binom{k+n-1}{n-1} = \frac{(k+n-1)!}{k!(n-1)!}$ GRT: $k+n-1 \text{ nCr } n-1$

Voorwaardelijke kans

Voorwaardelijke kans en onafhankelijke gebeurtenissen

- Voorwaardelijke kans of a posteriori kans $P(A | B)$ is de kans dat gebeurtenis A optreedt op voorwaarde dat gebeurtenis B optreedt.
- Onvoorwaardelijke kans is a priori kans

$$P(A | B) = \frac{P(A \cap B)}{P(B)} \text{ met } P(B) > 0$$

- Vermenigvuldigingsregel
 - $P(A \cap B) = P(B) P(A | B)$
EN $P(A \cap B) = P(A) P(B | A)$
- Onafhankelijke gebeurtenissen: een gebeurtenis A is onafhankelijke van gebeurtenis B indien het al dan niet optreden van B geen invloed heeft op het optreden van A
 - $P(A) = P(A | B)$ en $P(B) = P(B | A)$
 - We zeggen dat gebeurtenissen A_1, A_2, \dots, A_n onderling onafhankelijk zijn indien voor elke deelverzameling geldt dat
 $P(A_{i1} \cap A_{i2} \cap \dots \cap A_{ik}) = P(A_{i1})P(A_{i2})\dots P(A_{ik})$

Wet van de totale kans en de regel van Bayes

Wet van de totale kans

Beschouwen we een gebeurtenis A met onvoorwaardelijke kans $P(A)$. Indien de gebeurtenissen B_1, B_2, \dots, B_n een partitie van Ω vormen, dan kunnen we $P(A)$ schrijven als

$$P(A) = \sum_{i=1}^n P(A | B_i) P(B_i)$$

Bewijs zie pagina 49

- ⇒ $A = A \cap \Omega = A \cap (B_1 \cup B_2 \cup \dots \cup B_n) = \dots$
- ⇒ Dus $P(A) = P((A \cap B_1) \cup (A \cap B_2) \cup \dots \cup (A \cap B_n))$
- ⇒ Aangezien B_i en B_j disjunct zijn voor $i \neq j$, zijn ook $A \cap B_i$ en $A \cap B_j$ disjunct dus
- ⇒ $P(A) = P(A \cap B_1) + P(A \cap B_2) + \dots + P(A \cap B_n)$
- ⇒ $= P(A | B_1)P(B_1) + P(A | B_2)P(B_2) + \dots + P(A | B_n)P(B_n)$
- ⇒ Waaruit de formule onmiddellijk volgt.
- ⇒ De som van de voorwaardelijke kansen is dus niet gelijk aan $P(A)$

Regel van Bayes

Voor een partitie B_1, B_2, \dots, B_n van Ω en een willekeurige gebeurtenis A geldt

$$P(B_i | A) = \frac{P(A | B_i) P(B_i)}{\sum_{j=1}^n P(A | B_j) P(B_j)}$$

Dit volgt onmiddellijk uit de definitie van de voorwaardelijke kans want

$$P(B_i | A) = \frac{P(B_i \cap A)}{P(A)} = \frac{P(A | B_i) P(B_i)}{\sum_{j=1}^n P(A | B_j) P(B_j)}$$

enkel bij voorwaardelijke kans

Univariate kansvariabelen

Kansvariabelen en verdelingsfunctie

Een functie X die een uitkomstenruimte afbeeldt op \mathbb{R} noemen we een **kansvariabele** of stochastische variabele X .

$X = x$ interpreteren we als "de functie X heeft als waarde x "

De **kans** dat een kansvariabele een bepaalde x aanneemt, kunnen we afleiden uit de kans van de corresponderende gebeurtenis

$$\Rightarrow \text{Kansfunctie:} \quad P(X = x) = P(A) \quad \text{met } A = \{\omega \in \Omega \mid X(\omega) = x\}$$

Cumulatieve verdelingsfunctie:

$$\Rightarrow F_X(x) = P(X \leq x), \quad x \in \mathbb{R}$$

Omschrijving	Symbolen	Bewijs/verantwoord.
Kans op een uitkomst tussen 2 waarden	$P(x_1 < X \leq x_2)$ $= F_X(x_2) - F_X(x_1)$	$F_X(x_2) = P(X \leq x_2)$ $= P(X \leq x_1) + P(x_1 < X \leq x_2)$ $= F_X(x_1) + P(x_1 < X \leq x_2)$
Voorwaarden cumulatieve verdelingsfunctie	$x_1 < x_2 \Rightarrow F_X(x_2) \leq F_X(x_1)$ $\lim_{x \rightarrow -\infty} F_X(x) = 0$ $\lim_{x \rightarrow +\infty} F_X(x) = 1$	

Discrete kansvariabele

Een **discrete kansvariabele** is een kansvariabele die slechts een **eindig** of **afelbaar oneindig** aantal waarden kan aannemen.

$$p_X(m_i) = P(X = m_i) \text{ met } i = 1, 2, \dots, k$$

Omschrijving	Symbolen	Bewijs/verantwoord.
Kansverdeling	$p_X(m_i) \geq 0$ met $i = 1, \dots, k$ en $\sum_{i=1}^k p_X(m_i) = 1$	\Rightarrow Kans functie steeds + \Rightarrow uitkomst vh experiment steeds op 1 van de waarden wordt afgebeeld en $P(\Omega) = 1$

Cumulatieve verdelingsfunctie van een discrete kansvariabele:

$$\Rightarrow F_X(x) = P(X \leq x) = \sum_{m_i \leq x} p_X(m_i), \quad x \in \mathbb{R}$$

Continue kansvariabele

Een continue kansvariabele is een kansvariabele die een **oneindig** aantal waarden kan aannemen.

We kunnen GEEN kansverdeling meer opstellen omdat de variabele oneindig is. De kans dat een specifieke waarde zal voorkomen is dan bijgevolg ook 0.

→ **Kansdichtheid** $f_X(x)$ is de afgeleide van de verdelingsfunctie $F_X(x)$.

$$f_X(x) = \frac{d}{dx} F_X(x)$$

Merk op dat de kansdichtheid hier > 1 kan zijn.

Omschrijving	Symbolen	Bewijs/verantwoord.
Verdelingsfunctie bepalen uit kansdichtheid	$F_X(x') = P(X \leq x')$ $= \int_{-\infty}^{x'} f_X(x) dx$	De verdeling stemt dus overeen met opp onder kansdichtheid links van het punt x'
Voorwaarden kansdichtheid	* $f_X(x) \geq 0, \forall x \in R$ * $\int_{-\infty}^{\infty} f_X(x) dx =$ $\lim_{x \rightarrow +\infty} F_X(x) = 1$	*afgeleide is een stijgende functie *opp tussen kansdichtheid en horizontale as steeds gelijk aan 1
Kans op $X = x$	$P(X = x) = \int_x^x f_X(y) dy = 0$	$P(X \leq x) = P(X < x)$ En dus $P(x_1 < X \leq x_2)$ $= \int_{x_1}^{x_2} f_X(x) dx$

Kenmerken van populatie verdelingen

Verwachtingswaarde van een kansvariabele

Discrete variabele	Continue variabele
$\mu_X = E(X) = \sum_{i=1}^k m_i p_X(m_i)$	$\mu_X = E(X) = \int_{-\infty}^{\infty} x f_X(x) dx$

Omschrijving	Symbolen	Bewijs/verantwoord.
Lineaire transformatie	$Y = aX + b$ → $E(Y) = aE(X) + b$	$E(Y) = \int_{-\infty}^{\infty} (ax + b) f_X(x) dx$ $= a \int_{-\infty}^{\infty} x f_X(x) dx + b \int_{-\infty}^{\infty} f_X(x) dx$ $= aE(X) + b$
Verwachtingswaarde van een constante	$E(b) = b$	De VW ve constante is de constant zelf
Variabele centreren	$Y = X - E(X) = 0$	$E(Y) = E(X - E(X))$ $= E(X - \mu_X)$

MARKOV

Voor een willekeurige positieve kans variabele X op $[0, \infty]$ geldt dat

$$P(X \geq a) \leq \frac{E(X)}{a}, \quad \forall a > 0$$

Bewijs zie cursus pag 61

Variantie en standaardafwijking

⇒ VARIANTIE

$$\sigma_x^2 = Var(X) = E[(X - E(X))^2]$$

Discrete variabele	Continue variabele
$Var(X) = \sum_{i=1}^k (m_i - E(X))^2 p_X(m_i)$	$Var(X) = \int_{-\infty}^{\infty} (x - E(X))^2 f_X(x) dx$

⇒ STANDAARDAFWIJKING

$$\sigma_x = \sqrt{Var(X)}$$

Omschrijving	Symbolen	Bewijs/verantwoord.
Rekenformule	$Var(X) = E(X^2) - (E(X))^2$	Zie pag 62
Lineaire transformatie	$Y = aX + b$ $Var(Y) = a^2 Var(X)$ En $\sigma_y = a \sigma_x$	Zie pag 63
Variantie van een constante	$Var(b) = 0$	Variantie van een constant is 0
Gestandaardiseerde kansvariabele	$Z = \frac{X - \mu_x}{\sigma_x}$ met $E(Z) = 0$ & $Var(Z) = 1$	Zie pag 63

CHEBYSNEV

Voor een willekeurige kans variabele X geldt dat

$$P(|X - E(X)| \geq t) \leq \frac{Var(X)}{t^2}, \quad \forall t > 0$$

Bewijs zie cursus pag 64

Kwantielen, mediaan en kwartielen

⇒ KWANTIELFUNCTIE

- Is de inverse van de verdelingsfunctie
- De waarde van deze functie in een punt p is het p -kwantiel
- $Q_X(p) = \inf \{x \in \mathbb{R} \mid F_X(x) \geq p\}$ met $0 < p < 1$
- $\int_{-\infty}^{Q_X(p)} f_X(x) dx = p, \quad 0 < p < 1$

⇒ MEDIAAN

- $\text{Med}(X) = Q_X(0,5)$

Andere kenmerken

⇒ MODUS

- Waarde waarvoor de kansverdeling of kansdichtheid haar (lokaal) maximum bereikt

⇒ SCHEEFHEID

- $\gamma_X = \frac{E[(X - \mu_X)^3]}{\sigma_X^3}$
- Waarde < 0 dan linksscheef (links niets, rechts 'bult')
- Waarde > 0 dan rechtsscheef

⇒ KURTOSIS

- $\kappa_X = \frac{E[(X - \mu_X)^4]}{\sigma_X^4}$
- Geeft aan hoe dik de staarten zijn

Multivariate kans variabelen

Indien meerdere reële getallen geassocieerd worden met elke mogelijke uitkomst

Discrete multivariate kans variabelen

- Oneindig, aftelbaar aantal waarden kan aannemen
- $p(x_i, y_j) = P(X = x_i, Y = y_j) = P((X = x_i) \cap P(Y = y_j))$
- bv gooien met 2 dobbelstenen

Omschrijving	Symbolen	Bewijs/verantwoord.
Gezamenlijke kansverdeling	$p_x(x_i, y_i) \geq 0$ en $\sum_i \sum_j p(x_i, y_j) = 1$	
Marginale kansverdelingen	$p_x(x_i) = \sum_i p(x_i, y_i)$ en $p_y(y_j) = \sum_i p(x_i, y_j)$	Voor x sommeren over alle mogelijke waarden van y en omgekeerd

Continue multivariate kans variabelen

- Oneindig, onaftelbaar veel waarden kan aan nemen
- $p(x_i, y_j) = P(X = x_i, Y = y_j) = P((X = x_i) \cap P(Y = y_j))$

Omschrijving	Symbolen	Bewijs/verantwoord.
Gezamenlijke kansverdeling	$f(x, y) \geq 0$ en $\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) dx dy = 1$	
Marginale kansverdelingen	$f_x(x) = \int_{-\infty}^{\infty} f(x, y) dy$ $f_y(y) = \int_{-\infty}^{\infty} f(x, y) dx$	Om kansdichtheid $f_x(x)$ te bepalen integreren we over gezamenlijke kansdichtheid $f(x, y)$ met alle mogelijk waarden voor Y

Afhankelijkheid en voorwaardelijke verdeling

➤ **Afhankelijk vs onafhankelijk**

- $p(x_i, y_i) = p_X(x_i)p_Y(y_i)$
- $f(x, y) = f(x)f(y)$
 - Als het voldaan is **onafhankelijk**
 - Als het niet voldaan voor minstens 1 koppel is afhankelijk

➤ **Voorwaardelijke kansverdeling**

- $p_{X|Y}(x_i|y_i) = P(X = x_i|Y = y_i) = \frac{P(X=x_i, Y=y_i)}{P(Y=y_i)} = \frac{p(x_i, y_i)}{p_Y(y_i)}$

➤ **Voorwaardelijke kansdichtheden**

- $f_{X|Y}(x|y) = \frac{f(x, y)}{f_Y(y)}$ en $f_{Y|X}(y|x) = \frac{f(x, y)}{f_X(x)}$

Kenmerken

Verwachtingswaarde

Discrete variabele	Continue variabele
$E[g(X, Y)] = \sum_i \sum_j g(x_i, y_i)p(x_i, y_i)$	$E[g(X, Y)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y)f(x, y)dxdy$

Omschrijving	Symbolen	Bewijs/verantwoord.
VW van lineaire combinatie	$E(aX + bY + C)$ $= aE(X) + bE(Y) + c$	Zie pag 74
Factorisatie	Zijn X en Y onafhankelijk dan $E(XY) = E(X)E(Y)$	Zie pag 75

(Co)variantie en correlatie

⇒ COVARIANTIE

- $cov(X, Y) = E[(X - E(X))(Y - E(Y))]$

Discrete variabele	Continue variabele
$Cov(X, Y) = \sum_i \sum_j (x_i - E(X))(y_j - E(Y)) p(x_i, y_j)$	$Cov(X, Y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - E(X)) \cdot (y - E(Y)) f(x, y) dx dy$

⇒ CORRELATIECOEFFICIENT

- $\rho(X, Y) = \frac{Cov(X, Y)}{\sqrt{Var(X)Var(Y)}}$

Omschrijving	Symbolen	Bewijs/verantwoord.
VW van lineaire combinatie	$E(aX + bY + C)$ $= aE(X) + bE(Y) + c$	Zie pag 74
Factorisatie	Zijn X en Y onafhankelijk dan $E(XY) = E(X)E(Y)$	Zie pag 75
Lineaire transformatie	$Cov(a_1X + b_1, a_2Y + b_2)$ $= a_1a_2Cov(X, Y)$	Zie pag 77
Cov tussen onafhankelijke variabelen	Indien X en Y onafhankelijk zijn is $Cov(X, Y) = 0$	Volgt uit rekenformule ! omgekeerde niet waar!
Variantie van een lineaire combinatie	$Var(aX + bY + c)$ $= a^2Var(X) + b^2Var(Y) + 2abCov(X, Y)$	Zie pag 78
Voor onafhankelijke variabelen geldt	$Var(X + Y)$ $= Var(X) + Var(Y)$	
Covariantie en lineaire combinaties	$Cov(X + Y, Z)$ $= Cov(X, Z) + Cov(Y, Z)$	Zie pag 78

Discrete verdelingen

Uniforme verdeling

⇒ Als elke mogelijke waarde dezelfde kans heeft op te treden

Bernoulli verdeling

⇒ Hebben we als we een kansverdeling hebben die maar 2 waarden kan aannemen = binaire variabele

⇒ $X \sim B(1, p)$

Binomiale verdeling

⇒ Is een opeenvolging van identieke en onafhankelijke Bernoulli experimenten

⇒ $X \sim B(n, p)$

⇒ Kansverdeling $P(X = k) = \text{Binompdf}(n, p, k)$

⇒ Cumulatieve verdelingsfunctie $P(X \leq k) = \text{Binomcdf}(n, p, k)$

Omschrijving	Symbolen	Bewijs/verantwoord.
Som van binomiale verdeling	$Z = X_1 + X_2 \sim B(n_1 + n_2, p)$	2 onafhankelijke binomiaal verdeelde kans variabelen met zelfde parameter, daarvan is de som ook binomiaal verdeeld.
Aantal mislukkingen	$Y = n - X \sim B(n, 1 - p)$	
Wet van de grote aantallen	$\lim_{n \rightarrow \infty} P\left(\left \frac{Y_N}{n} - p\right \geq \epsilon\right) = 0$	Gebaseerd op Chebyshev. Zie pag 88

Poisson verdeling

⇒ Kan beschouwd worden als de limiet van de binomiale verdeling met $\lambda = np$

⇒ $X \sim \text{Poisson}(\lambda)$

⇒ Kansverdeling $P(X = k) = \text{Poissonpdf}(\lambda, k)$

⇒ Cumulatieve verdelingsfunctie $P(X \leq k) = \text{Poissoncdf}(\lambda, k)$

⇒ Voorwaarden

- λ is de intensiteit = gemiddeld aantal gebeurtenissen in gekozen eenheid
- gebeurtenissen komen niet in groep voor m.a.w. de kans op 2 of meer gebeurtenissen binnen eenzelfde interval is verwaarloosbaar t.o.v. de kans op 1 of geen gebeurtenis
- de kans dat zich voordoet in een bepaald interval is dezelfde voor alle intervallen
- of een gebeurtenis zich voordoet in een bepaald interval is onafhankelijk van wat in de andere intervallen gebeurt

⇒ bv aantal oproepen in een callcenter, aantal tikfouten in een krant, aantal voertuigen dat voorbij rijdt in een bepaalde tijd

Omschrijving	Symbolen	Bewijs/verantwoord.
Som van poisson verdelingen	$Z = X_1 + X_2 \sim \text{Poisson}(\lambda_1 + \lambda_2)$	2 onafhankelijke poisson verdeelde kans variabelen, daarvan is de som ook poisson verdeeld.

Geometrische verdeling

- ⇒ Een opeenvolging van identieke of onafhankelijk Bernoulli experimenten met kans p of succes. We zijn nu echter niet geïnteresseerd op aantal successen, maar **in het aantal experimenten dat nodig is om een eerste succes te observeren**
- ⇒ Als het eerste succes optreedt in experiment k, moeten we bij de k-1 experimenten immers een mislukking hebben geobserveerd.
- ⇒ $F_x(k) = 1 - (1-p)^k$
- ⇒ Bv sollicitatie, lotto
- ⇒ Heeft geen geheugen, de kansen blijven gelijk.

Omschrijving	Symbolen	Bewijs/verantwoord.
Geheugenloosheid	Indien X geometrisch verdeeld is, dan geldt voor $k_1 > 0$ en $k_2 > 0$ dat $P(X > k_1 + k_2 \mid X > k_1) = P(X > k_2)$	Zie pag 95

Hypergeometrische verdeling

- ⇒ Eindige populatie van grootte N bestaande uit r elementen met uitkomst 1 (succes) en N - r elementen met uitkomst 0 (mislukking). Uit die populatie trekken we lukraak en zonder teruglegging een steekproef van $n \leq N$ -elementen. Het aantal successen X in deze steekproef heeft dan een hypergeometrische verdeling
- ⇒ Bv capture – recapture methode
 - Wordt gebruikt om de grootte van een populatie in te schatten o.b.v. 2 of meer onvolledige lijsten
 - Eerste groep vangen en kenmerken dan weer vrijlaten
 - Tweede groep vangen en kijken hoeveel er gekenmerkt zijn
 - Schatten aantal dieren, drugsgebruikers, HIV-patiënten, aantal personen die de belastingen ontduiken

Continue verdelingen

Uniforme verdeling

⇒ De kansvariabele X is uniform verdeeld over het interval (a, b) als de kansdichtheid constant is over (a, b)

$$\Rightarrow f_x(x) = \begin{cases} \frac{1}{b-a} & a \leq x \leq b \\ 0 & \text{elders} \end{cases}$$

Exponentiële verdeling

$$\Rightarrow f_x(x) = \begin{cases} \lambda e^{-\lambda x} & x \geq 0 \\ 0 & \text{elders} \end{cases}$$

⇒ bv wachtrij in een postkantoor

Omschrijving	Symbolen	Bewijs/verantwoord.
Verband met Poisson verdeling		Zie pag 99-110 EXAMEN!
Geheugenloosheid	Indien X exp verdeeld is, $P(X > t_1 + t_2 \mid X > t_1)$ $= P(X > t_2)$	Zie pag 100 Belangrijk!

Normale verdeling

Definitie en kenmerken

$$\Rightarrow f_x(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

⇒ Standaardnotatie: $X \sim N(\mu, \sigma^2)$

⇒ De verwachtingswaarde $E(X)$

- Geeft de kansdichtheid en de symmetrie rond μ weer
- Is locatieparameter
- Geeft locatie van de klokkurve weer

⇒ Variantie geeft de schaalcurve weer

- Als sigma groot is, is er een grote spreiding
- Platte of hoge klokkurve

Standaard normale verdeling

⇒ Is de normale verdeling met $\mu = 0$ en $\sigma = 1$

⇒ $\mu < 0$ naar links en $\mu > 0$ naar rechts verschuiven

⇒ $\sigma < 1$ uitrekken naar boven, wordt smaller en $\sigma > 1$ inkrimpen naar beneden, wordt breder

⇒ Normalpdf en normalcdf

Omschrijving	Symbolen	Bewijs/verantwoord.
Negatieve waarden	$F(-z) = 1 - F(z)$	zie pag 102
Kwantielfunctie $p < 0,5$	$F^{-1}(1-p) = -F^{-1}(p)$	Zie pag 103 & invNorm

Willekeurige normale verdeling

Omschrijving	Symbolen	Bewijs/verantwoord.
Lineaire transformatie	$Y \sim N(a\mu + b, a^2\sigma^2)$	zie pag 104
Omzetten standaardnormale verdeling	$Z = \frac{X - \mu}{\sigma}$	

Centrale limietstelling

- ⇒ Is een van de basisresultaten uit de statistiek
- ⇒ Ze stelt dat de som van n onafhankelijke kans variabelen X_i voor $n \rightarrow \infty$ normaal verdeeld is, ongeacht de verdelingen van de kans variabelen.

Centrale limietstelling

Beschouw n onafhankelijke kansvariabelen X_1, X_2, \dots, X_n met willekeurige kansverdeling of dichtheid en met $E(X) = \mu_i$ en $\text{Var}(X_i) = \sigma_i^2$. Onder bepaalde technische voorwaarden geldt voor $Y_n = X_1 + X_2 + \dots + X_n$ dat

$$\lim_{n \rightarrow \infty} P \left(\frac{Y_n - \sum_{i=1}^n \mu_i}{\sqrt{\sum_{i=1}^n \sigma_i^2}} \right)$$

Voor voldoende grote waarvan van n is Y_n bij benadering normaal verdeeld. Als de kans variabelen alle dezelfde verdeling hebben met $E(X_i) = \mu$ en $\text{Var}(X_i) = \sigma^2$, dan

$$\lim_{n \rightarrow \infty} P \left(\frac{Y_n - n\mu}{\sigma\sqrt{n}} \right)$$

Enkele vuistregels als de kans variabelen dezelfde verdeling hebben

- ⇒ De kansdichtheid wijkt niet te sterk van de normale als $n \geq 5$
- ⇒ De kansverdeling of -dichtheid vertoont geen al te grote pieken: $n \leq 12$
- ⇒ Voor andere continue kans variabelen die in de praktijk voorkomen: $n \geq 30$

Omschrijving	Symbolen	Bewijs/verantwoord.
Normale verdeling van de binomiale verdeling	$B(n, p) \approx N(np, np(1 - p))$	De binomiale verdeling voor voldoende grote n kan normaal verdeeld benaderd worden

- ⇒ Continuïteitscorrectie
 - Als we een binomverdeling hebben waarbij $np > 5$ en $n(1-p) > 5$ dan kunnen we de verdeling normaal benaderen met normale verdeling
 - Continuïteitscorrectie is dan $+1/2$ of $-1/2$ of beide

χ^2 -verdeling

- ⇒ Chi-kwadraat verdeling
- ⇒ Belangrijk in verklarende statistiek
- ⇒ n = aantal vrijheidsgraden

Omschrijving	Symbolen	Bewijs/verantwoord.
Karakterisatie	$Z_1^2 + Z_2^2 + \dots + Z_n^2 \sim \chi_n^2$	Een KV die chi-kwadratische verdeling heeft kunnen we schrijven als een som van n onafhankelijke kwadraten

- ⇒ χ^2 pdf, χ^2 cdf en INVCHI2

t- verdeling

- ⇒ Belangrijk in verklarende statistiek
- ⇒ n = aantal vrijheidsgraden
- ⇒ Als n oneindig groot wordt, vinden we de standaard normale dichtheid terug
- ⇒ De t-verdeling is dus een symmetrische verdeling met zwaardere staarten dan de normale verdeling

Omschrijving	Symbolen	Bewijs/verantwoord.
Karakterisatie	$\frac{X}{\sqrt{Y/n}} \sim t_n$ met $X \sim N(0,1)$ en $Y \sim \chi_n^2$ onafhankelijk	KV is t-verdeeld asa de V kan geschreven worden als quotiënt van (zie formule)

- ⇒ De variantie zal steeds groter zijn dan bij de standaard normale verdeling
- ⇒ Tcdf, tpdf en invT

F-verdeling

- ⇒ Heeft twee parameters waarvan de volgorde BELANGRIJK is!
- ⇒ $X \sim F_{n,m}$
- ⇒ Wordt gebruikt voor de vergelijking van 2 groepen

Omschrijving	Symbolen	Bewijs/verantwoord.
Karakterisatie	$\frac{X/n}{Y/m} \sim F_{n,m}$	En KV is F-verdeeld asa de variabele geschreven kan worden als quotiënt van twee onafhankelijke chikwadraat verdeelde KV

- ⇒ Fcdf, Fpdf en InvF

Bivariate normale verdeling

- ⇒ Multivariate uitbreiding van de normale verdeling
- ⇒ Kansvariabelen X en Y allebei normaal verdeeld
- ⇒ $\text{Cov}(X, Y) = \rho\sigma_X\sigma_Y$ met ρ de correlatie
- ⇒ Zie cursus pag 111 ev