

WESTFÄLISCHE  
WILHELMS-UNIVERSITÄT  
MÜNSTER

# **Über die Verteilung der Länge externer Zweige in Koaleszenzbäumen: Genetische Vielfalt innerhalb einer Spezies**

Diplomarbeit  
von  
Thomas Uckelmann

September 2012

Betreut durch Prof. Dr. Gerold Alsmeyer  
Institut für Mathematische Statistik

# Inhaltsverzeichnis

<b>1. Allgemeine Grundlagen</b>	<b>1</b>
1.1. Markov-Prozesse in stetiger Zeit	2
1.2. Markov-Sprungprozesse	4
1.3. Die minimale Konstruktion	7
<b>2. ATGC's of life</b>	<b>11</b>
2.1. Das Wright-Fisher Modell	12
<b>3. Der Koaleszenzprozess nach Kingman</b>	<b>16</b>
3.1. Der $n$ -Koaleszenzprozess	16
3.2. Die Sprung-Kette	20
3.3. Der Koaleszenzprozess	23
3.4. Genealogische Bäume	31
<b>4. Längenverteilung externer Zweige in Koaleszenzbäumen</b>	<b>37</b>
4.1. Eine alternative Darstellung von $Z_n$	41
<b>A. Appendix</b>	<b>57</b>

# Einleitung

Der  $n$ -Koaleszenzprozess nach Kingman [15] ergibt sich als asymptotisches Modell für die Genealogie von  $n$  Individuen einer haploiden Population der Größe  $2N$  unter dem Wright-Fisher Modell. Dabei lässt sich der  $n$ -Koaleszenzprozess in natürlicher Weise als baumwertiger Prozess auffassen.

In [17] wurde als mögliches Maß für die genetische Vielfalt einer Population die *Einzigartigkeit eines Individuums* als Zeit bis zum zeitlich nähesten gemeinsamen Vorfahren eines Individuums und seines nächsten Verwandten innerhalb der Population eingeführt.

Für diese wurde unter Betrachtung von Laplace-Transformierten von Caliebe et al. in [7] das Ergebnis geliefert, dass sie asymptotisch einer Verteilung mit Dichte  $x \rightarrow 8/(2+x)^3$ ,  $x \geq 0$ , genügt. Genauer wurde gezeigt, dass die Länge  $Z_n$  eines zufällig gewählten externen Zweiges eines Koaleszenzbaumes der Konvergenzeigenschaft  $nZ_n \xrightarrow{d} Z$  genügt, wobei die Dichte von  $Z$  gerade der eben gegebenen entspricht.

Eine unweigerliche Konsequenz ist damit, dass die genetische Vielfalt einer Population auf eine geringe Anzahl Individuen konzentriert ist. Insbesondere kann daher der Verlust einzelner Individuen große Auswirkungen auf die genetische Vielfalt der Population haben.

Eine andere Betrachtungsweise ergibt sich mit Blick auf [12]. Dort wurde die Länge aller externen Zweige im Verhältnis zur Länge der internen Zweige untersucht. Die dahinterliegende Frage ist, ob die Annahme von neutraler Selektion für eine gegebene Population mit Mutationseinfluss gerechtfertigt ist. Die Länge aller externen Zweige korrespondiert dabei zu der Zeit, in der Mutationen auftreten können, welche nur ein Individuum betreffen können.

In [13] wurde gezeigt, dass für die Gesamtlänge  $L_n$  der externen Zweige eines Koaleszenzprozesses nach Kingman mit  $n$  externen Zweigen die Verteilungskonvergenz

$$\frac{1}{2} \sqrt{\frac{n}{\ln n}} (L_n - 2) \xrightarrow{d} N(0, 1)$$

für  $n \rightarrow \infty$  gilt, wobei wie üblich mit  $N(0, 1)$  eine Normalverteilung mit Erwartung 0 und Varianz 1 bezeichnet sei.

## *Inhaltsverzeichnis*

---

Vermöge der Unabhängigkeit des Koaleszenzprozesses und des Mutationsprozesses in einem Koaleszenzprozess mit Mutation, kann die Länge der externen Zweige herangezogen werden, um die Anzahl von Mutationen auf den externen Zweigen zu bestimmen. Die Länge eines zufällig gewählten externen Zweiges korrespondiert unter dieser Betrachtung mit der Zeit, in der Mutationen das ausgewählte Individuum im Vergleich zu seinem nächsten Verwandten verändern können.

Entsprechend des asymptotischen Ergebnisses für die Länge eines externen Zweiges lässt sich die Verteilung der Anzahl der Mutationen auf einem externen Zweig angeben.

In dieser Arbeit wollen wir das Ergebnis von Caliebe et al. rekapitulieren.

Ich danke Herrn Prof. Dr. Gerold Alsmeyer für diesen Themenvorschlag und im Besonderen für seine Geduld mit mir. Des Weiteren möchte ich mich bei meiner Familie für die Unterstützung während meiner Studienzeit bedanken.

# 1. Allgemeine Grundlagen

Dieses Kapitel dient dazu, einige grundlegende Definitionen und Ergebnisse der Theorie der Markov-Sprungprozesse anzugeben, auf die im Folgenden verwiesen wird. Darüber hinaus werden wir größtenteils auf Beweise verzichten.

Bevor wir damit allerdings beginnen, wollen wir noch einige allgemeinere Definitionen treffen und halten entsprechend fest, dass wir mit einer Exponentialverteilung mit Parameter  $\lambda$ , kurz  $\text{Exp}(\lambda)$ , eine Verteilung bezeichnen, deren Verteilungsfunktion durch  $(1 - e^{-\lambda x})\mathbb{1}_{[0, \infty)}(x)$  gegeben ist. Insbesondere berechnet sich der Erwartungswert in diesem Fall zu  $1/\lambda$ . Ebenfalls wollen wir  $\mathcal{O}$  in der üblichen Bedeutung des Landau-Kalküls verstehen.

## 1.1 Definition

Ein topologischer Raum  $(S, \mathfrak{T})$  heißt *polnisch*, wenn eine die Topologie  $\mathfrak{T}$  erzeugende Metrik  $\varrho$  existiert, so dass  $(S, \varrho)$  ein separabler, vollständiger metrischer Raum ist.

## 1.2 Definition

Sei  $(M, d)$  ein metrischer Raum und bezeichne  $\mathbb{R}_+ = [0, \infty)$ . Dann heißt eine Funktion  $f : \mathbb{R}_+ \rightarrow M$  *càdlàg* (aus dem Französischen »*continue à droite, limite à gauche*«), falls

- (i)  $f(t) = \lim_{s \downarrow t} f(s)$  für alle  $t \geq 0$ , und
- (ii)  $f(t-) = \lim_{s \uparrow t} f(s)$  für alle  $t > 0$  existiert.

$f$  ist also rechtsseitig stetig und besitzt linksseitige Limiten.

Wir nennen ferner einen stochastischen Prozess  $(X_t)_{t \geq 0}$  *càdlàg*, falls dies für seine Pfade der Fall ist.

## 1.3 Definition

Gegeben einen Wahrscheinlichkeitsraum  $(\Omega, \mathfrak{A}, P)$  mit einer Filtration  $\mathcal{F} = (\mathcal{F}_t)_{t \geq 0}$ , heißt eine nichtnegative Zufallsvariable  $\tau$  *Stoppzeit bezüglich*  $\mathcal{F}$ , falls

$$\{\tau \leq t\} \in \mathcal{F}_t, \quad (1.1)$$

für alle  $t \geq 0$  gilt. Wir bezeichnen ferner mit

$$\mathcal{F}_\tau \stackrel{\text{def}}{=} \{A \in \mathfrak{A} : A \cap \{\tau \leq t\} \in \mathcal{F}_t\} \quad (1.2)$$

die  $\sigma$ -Algebra der  $\tau$ -Vergangenheit.

## 1.1. Markov-Prozesse in stetiger Zeit

Für die allgemeine Betrachtung von Markov-Prozessen in stetiger Zeit in [1], auf die wir hier für die Beweise der Sätze verweisen, setzen wir voraus, dass der Zustandsraum  $(S, \mathfrak{S})$  eines stochastischen Prozesses  $X = (X_t)_{t \geq 0}$  auf einem Wahrscheinlichkeitsraum  $(\Omega, \mathfrak{A}, P)$  lokalkompakt und mit abzählbarer Basis sei, sowie  $\mathfrak{S}$  die zugehörigen Borelschen  $\sigma$ -Algebra bezeichne. Da damit  $(S, \mathfrak{S})$  insbesondere polnisch ist, existieren die im Folgenden auftretenden (regulär) bedingten Verteilungen (vgl. Satz 53.4 in [2]).

### 1.4 Definition (Markov-Prozess)

Sei  $X = (X_t)_{t \geq 0}$  ein stochastischer Prozess auf einem Wahrscheinlichkeitsraum  $(\Omega, \mathfrak{A}, P)$  mit Zustandsraum  $(S, \mathfrak{S})$  und  $\mathcal{F} = (\mathcal{F}_t)_{t \geq 0}$  eine Filtration.

$X$  heißt *Markov-Prozess bezüglich  $\mathcal{F}$* , wenn er  $\mathcal{F}$ -adaptiert ist und die *Markov-Eigenschaft*, gegeben durch

$$P(X_t \in A | \mathcal{F}_s) = P(X_t \in A | X_s) \quad P\text{-f.s.} \quad (1.3)$$

für alle  $0 \leq s < t < \infty$  und  $A \in \mathfrak{S}$ , besitzt. Ferner bezeichne

$$\mathbb{P}_{s,t}(X_s, A) \stackrel{\text{def}}{=} P(X_t \in A | X_s) \quad (1.4)$$

für alle  $0 \leq s < t < \infty$  und  $A \in \mathfrak{S}$  die zugehörigen Übergangskerne. Falls diese so gewählt werden können, dass sie lediglich über  $s - t$  von  $s$  und  $t$  abhängen, das heißt, falls

$$P(X_t \in A | \mathcal{F}_s) = P(X_t \in A | X_s) = \mathbb{P}_{0,t-s}(X_s, A) \quad P\text{-f.s.}$$

gilt, so heißt  $X$  *zeitlich homogen*.

Im Fall der natürlichen Filtration  $\mathcal{G} = (\mathcal{G}_t)_{t \geq 0}$ , mit  $\mathcal{G}_t = \sigma(X_s, s \leq t)$ , verzichten wir auf den Zusatz *bezüglich  $\mathcal{G}$* .

Ist der Zustandsraum  $(S, \mathfrak{S})$  abzählbar, so nennen wir  $X$  einen *Markov-Sprungprozess* oder auch *zeitstetige Markovkette*.

### 1.5 Definition

Wir sagen, ein Markov-Prozess  $X = (X_t)_{t \geq 0}$  bezüglich einer Filtration  $\mathcal{F} = (\mathcal{F}_t)_{t \geq 0}$  mit Zustandsraum  $(S, \mathfrak{S})$  auf einem Wahrscheinlichkeitsraum  $(\Omega, \mathfrak{A}, P)$ , erfülle die *starke Markov-Eigenschaft bezüglich  $\tau$* , wenn, bedingt unter  $\{\tau < \infty\}$ ,

$$P(X_{\tau+t} \in A | \mathcal{F}_\tau) = P(X_{\tau+t} \in A | X_\tau) = \mathbb{P}_{\tau, \tau+t}(X_\tau, A) \quad P\text{-f.s.} \quad (1.5)$$

für alle  $A \in \mathfrak{S}$  und  $t \geq 0$  für eine Stoppzeit  $\tau$  bezüglich  $\mathcal{F}$  gilt. Im Fall eines homogenen Prozesses vereinfacht sich die Gestalt von (1.5) zu

$$P(X_{\tau+t} \in A | \mathcal{F}_\tau) = \mathbb{P}_{0,t}(X_\tau, A) \quad P\text{-f.s.} \quad (1.6)$$

### 1.6 Bemerkung

Die Definition der *starken Markov-Eigenschaft* für beliebige Markov-Prozesse in stetiger Zeit verwendet rechtsseitig stetige  $\sigma$ -Algebren, beziehungsweise rechtsseitig stetige Erweiterungen (vgl. Seite 57 in [8]). Für einen Markov-Prozess  $X = (X_t)_{t \geq 0}$  bezüglich einer rechtsseitig stetigen Filtration  $\mathcal{F} = (\mathcal{F}_t)_{t \geq 0}$  sagen wir dann, dass dieser die *starke Markov-Eigenschaft* besitze, falls für jede Stoppzeit  $\tau$  bezüglich  $\mathcal{F}$  bedingt unter  $\{\tau < \infty\}$  (1.5) gilt.

Die im Folgenden betrachteten Markov-Prozesse seien nunmehr stets zeitlich homogen. Wir führen deshalb  $\mathbb{P}_t = \mathbb{P}_{0,t}$  als abkürzende Schreibweise für die Übergangskerne ein. Darüber hinaus setzen wir  $\mathbb{P}_0(x, \cdot) \stackrel{\text{def}}{=} \delta_x$ , wobei  $\delta_x$  die Einpunktverteilung in  $x$  bezeichnet.

Für die Übergangskerne eines homogenen Markov-Prozesses gelten die *Kolmogorov-Chapman-Gleichungen* als einfache Konsequenz der Rechenregeln für stochastische Kerne:

### 1.7 Lemma

Für die Familie  $(\mathbb{P}_t)_{t \geq 0}$  der Übergangskerne eines zeitlich homogenen Markov-Prozesses gelten die *Kolmogorov-Chapman-Gleichungen*, das heißt

$$\mathbb{P}_{s+t} = \mathbb{P}_s \mathbb{P}_t. \quad (1.7)$$

$(\mathbb{P}_t)_{t \geq 0}$  bildet damit eine Halbgruppe (bezüglich der Hintereinanderschaltung von Kernen).

Wir weisen ebenfalls darauf hin, dass zu jeder Halbgruppe  $(\mathbb{P}_t)_{t \geq 0}$  von Übergangskernen auf  $(S, \mathfrak{S})$  mit  $\mathbb{P}_0(x, \cdot) = \delta_x$  ein Markov-Prozess existiert. Darüber hinaus kann die Anfangsverteilung  $\lambda \in \mathfrak{W}(S)$ , wobei  $\mathfrak{W}(S)$  die Menge der Wahrscheinlichkeitsmaße auf  $S$

bezeichne, beliebig gewählt werden. Dies ergibt sich als Anwendung des Konsistenzsatzes von Daniell-Kolmogorov.

Insbesondere erlaubt uns dies die Betrachtung von Räumen

$$(\Omega, \mathfrak{A}, (X_t)_{t \geq 0}, (\mathbb{P}_\lambda)_{\lambda \in \mathfrak{W}(S)}), \quad (1.8)$$

in denen  $X = (X_t)_{t \geq 0}$  unter jedem  $\mathbb{P}_\lambda$  ein Markov-Prozess mit Übergangskernen  $\mathbb{P}_t$  und Anfangsverteilung  $\lambda$  ist. Wir nennen dann (1.8) ein *Standardmodell* für  $(\mathbb{P}_t)_{t \geq 0}$ .

### 1.8 Bemerkung

Es bezeichne  $b\mathfrak{S}$  den Raum der beschränkten Funktionen  $f : \mathfrak{S} \rightarrow \mathfrak{S}$ , versehen mit der Supremumsnorm  $\|\cdot\|_\infty$ . Wir setzen ferner

$$\mathbb{P}_t f(x) \stackrel{\text{def}}{=} \int_S f(y) \mathbb{P}_t(x, dy) \quad (1.9)$$

für alle  $f \in b\mathfrak{S}$ . Vermöge der  $\mathfrak{A}$ -Messbarkeit von  $x \rightarrow \mathbb{P}_t(x, A)$  für alle  $A \in \mathfrak{S}$ , definiert dies einen linearen Operator von  $b\mathfrak{S}$  nach  $b\mathfrak{S}$ . Für diesen Operator gilt ferner  $\mathbb{P}_t f \geq 0$  für alle nichtnegativen  $f \in b\mathfrak{S}$ ,  $\|\mathbb{P}_t f\|_\infty \leq \|f\|_\infty$  für alle  $f \in b\mathfrak{S}$ , das heißt,  $\mathbb{P}_t$  ist eine *positive Kontraktion*, und man nennt  $(\mathbb{P}_t)_{t \geq 0}$  deshalb auch eine *positive Kontraktionshalbgruppe*.

### 1.9 Definition

Eine Übergangshalbgruppe  $(\mathbb{P}_t)_{t \geq 0}$  heißt *stochastisch*, falls  $\|\mathbb{P}_t\| = 1$  für alle  $t \geq 0$  gilt und andernfalls *substochastisch*. Dabei bezeichnet  $\|\cdot\|$  die Operatornorm, definiert durch

$$\|\mathbb{P}_t\| \stackrel{\text{def}}{=} \sup\{\|\mathbb{P}_t f\| : \|f\|_\infty = 1\}. \quad (1.10)$$

## 1.2. Markov-Sprungprozesse

Sei nunmehr der Zustandsraum  $(S, \mathfrak{S})$  abzählbar. Für einen Markov-Sprungprozess gemäß 1.4 stellen wir fest:

### 1.10 Definition

Gegeben einen Markov-Sprungprozess  $X = (X_t)_{t \geq 0}$  auf einem abzählbaren Zustandsraum  $(S, \mathfrak{S})$  mit Übergangshalbgruppe  $(\mathbb{P}_t)_{t \geq 0}$ , wird dieser bereits eindeutig durch  $p_{ij}(t) \stackrel{\text{def}}{=} \mathbb{P}_t(i, \{j\})$  für  $i, j \in S$  festgelegt. Wir definieren deshalb

$$\mathbf{P}(t) \stackrel{\text{def}}{=} (p_{ij}(t))_{i,j \in S} \quad (1.11)$$

für alle  $t \geq 0$  und nennen  $(\mathbf{P}(t))_{t \geq 0}$  die zu  $X$  gehörende *Übergangsmatrixfunktion*.

### 1.11 Bemerkung

Für die Übergangsmatrixfunktion  $(\mathbf{P}(t))_{t \geq 0}$  eines Markov-Sprungprozesses  $X = (X_t)_{t \geq 0}$  gelten

- (i)  $p_{ij}(t) \geq 0$  für alle  $t \geq 0$  und  $i, j \in S$ , sowie  $p_{ij}(0) = \delta_{ij}$ , wobei  $\delta_{ij}$  das Kronecker-Delta bezeichnet, und damit  $\mathbf{P}(0) = (\delta_{ij})_{i,j \in S} = I$ ,
- (ii)  $\sum_{j \in S} p_{ij}(t) \leq 1$  für alle  $t \geq 0$  und  $i, j \in S$ ,
- (iii)  $p_{ij}(s + t) = \sum_{k \in S} p_{ik}(s)p_{kj}(t)$ , genannt *Kolmogorov-Chapman-Gleichungen*; die Halbgruppeneigenschaft lässt sich also bezüglich der gewöhnlichen Matrix-Multiplikation als

$$\mathbf{P}(s + t) = \mathbf{P}(s)\mathbf{P}(t) \quad (1.12)$$

darstellen.

### 1.12 Definition

Eine Matrix  $\mathbf{P} = (p_{ij})_{i,j \in S}$  heißt *stochastisch*, falls

$$p_{ij} \geq 0, \text{ und } \sum_{j \in S} p_{ij} = 1 \quad (1.13)$$

für alle  $i, j \in S$  gilt.

Dementsprechend nennen wir eine Übergangsmatrixfunktion  $(\mathbf{P}(t))_{t \geq 0}$  eines Markov-Sprungprozesses *stochastisch*, falls  $\mathbf{P}(t)$  für alle  $t \geq 0$  stochastisch ist. Andernfalls nennen wir  $(\mathbf{P}(t))_{t \geq 0}$  *substochastisch*.

### 1.13 Definition

Gegeben eine Übergangsmatrixfunktion  $(\mathbf{P}(t))_{t \geq 0}$ , nennen wir diese eine *Standard-Übergangsmatrixfunktion*, falls ihre einzelnen Komponenten stetig in 0 sind, das heißt, falls

$$\lim_{t \downarrow 0} p_{ij}(t) = p_{ij}(0) = \delta_{ij} \quad (1.14)$$

für alle  $i, j \in S$  gilt.

### 1.14 Satz

Gegeben eine Standard-Übergangsmatrixfunktion  $(\mathbf{P}(t))_{t \geq 0}$ , so ist jedes  $p_{ij}(t)$  für alle  $t > 0$  stetig differenzierbar. Für  $t = 0$  gilt zumindest noch die (rechtsseitige) Differenzierbarkeit. Bezeichnet nun

$$q_{ij} \stackrel{\text{def}}{=} \lim_{t \downarrow 0} t^{-1} (p_{ij}(t) - p_{ij}(0)), \quad (1.15)$$

so gilt ferner  $|q_{ij}| < \infty$ , falls  $i \neq j$  und  $q_{ii} < \infty$  (kann aber den Wert  $-\infty$  annehmen).

### 1.15 Definition

Gegeben eine Standard-Übergangsmatrixfunktion  $(\mathbf{P}(t))_{t \geq 0}$ , eines Markov-Sprungprozesses  $X = (X_t)_{t \geq 0}$ , setzen wir

$$\mathbf{Q} \stackrel{\text{def}}{=} (q_{ij})_{i,j \in S} \quad (1.16)$$

und bezeichnen  $\mathbf{Q}$  als *Q-Matrix* von  $X$ .

Gegeben eine Q-Matrix  $\mathbf{Q}$  eines Markov-Sprungprozesses  $X = (X_t)_{t \geq 0}$ , gilt  $q_{ij} \geq 0$  für alle  $i, j \in S$  mit  $i \neq j$  vermöge  $t^{-1}(p_{ij}(t) - p_{ij}(0)) = t^{-1}p_{ij}(t) \geq 0$  für alle  $t \geq 0$ . Eine ähnliche Überlegung liefert darüber hinaus auch  $q_{ii} \leq 0$ . Setze nunmehr

$$q_i \stackrel{\text{def}}{=} -q_{ii} \text{ für alle } i \in S. \quad (1.17)$$

Eine Anwendung von Fatous Lemma bezüglich des Zählmaßes auf den Paaren  $(i, j)$  mit  $i \neq j$  liefert ferner

$$\sum_{i \neq j} q_{ij} = \sum_{i \neq j} \lim_{t \downarrow 0} \frac{p_{ij}(t)}{t} \leq \liminf_{t \downarrow 0} \sum_{i \neq j} \frac{p_{ij}(t)}{t} = \lim_{t \downarrow 0} \frac{1 - p_{ii}(t)}{t} = q_i. \quad (1.18)$$

### 1.16 Definition

Eine Q-Matrix  $\mathbf{Q}$  heißt *konservativ*, falls

$$\sum_{j \neq i} q_{ij} = q_i < \infty \quad (1.19)$$

für alle  $i \in S$  gilt.

### 1.17 Satz

Gegeben eine Standard-Übergangsmatrixfunktion  $(\mathbf{P}(t))_{t \geq 0}$  mit konservativer Q-Matrix  $\mathbf{Q}$ . Dann ist  $\mathbf{Q}$  der Generator der Halbgruppe mit Definitionsbereich

$$\mathcal{D}(\mathbf{Q}) = \left\{ f \in b\mathfrak{S} : \exists g \in b\mathfrak{S} : \lim_{t \downarrow 0} \|t^{-1}(\mathbf{P}(t)f - f) - g\|_\infty = 0 \right\}.$$

### 1.18 Satz

Jeder càdlàg-Markov-Sprungprozess, das heißt jeder Markov-Sprungprozess mit rechtsseitig stetigen, stückweise konstanten Pfaden, besitzt die starke Markov-Eigenschaft.

### 1.19 Definition

Für einen Markov-Sprungprozess  $X = (X_t)_{t \geq 0}$  auf einem Zustandsraum  $(S, \mathfrak{S})$  mit Übergangsmatrixfunktion  $(\mathbf{P}(t))_{t \geq 0}$  und zugehöriger Q-Matrix  $\mathbf{Q} = (q_{ij})_{i,j \in S}$  und  $q_i = -q_{ii}$  für  $i \in S$ , bezeichnen wir einen Zustand  $i \in S$  als

- (i) *stabil*, falls  $0 < q_i < \infty$ ,
- (ii) *absorbierend*, falls  $q_i = 0$ ,
- (iii) *augenblicklich*, falls  $q_i = \infty$ .

Darüber hinaus bezeichnen wir eine Übergangsmatrixfunktion als *stabil*, wenn alle Zustände  $i \in S$  stabil sind.

In konservativen Markov-Sprungprozessen gibt es keine augenblickliche Zustände.

### 1.20 Definition

Ein konservativer Markov-Sprungprozess  $X = (X_t)_{t \geq 0}$  mit Werten in  $\mathbb{N}_0$  heißt *Geburts- und Todesprozess* (in stetiger Zeit), falls er von jedem Zustand  $n$  lediglich in die Nachbarzustände  $n-1, n+1$  springen kann. Die dazugehörige Q-Matrix ist von der Gestalt

$$\mathbf{Q} = \begin{pmatrix} -\lambda_0 & \lambda_0 & 0 & 0 & 0 & \cdots \\ \mu_1 & -(\lambda_1 + \mu_1) & \lambda_1 & 0 & 0 & \cdots \\ 0 & \mu_2 & -(\lambda_2 + \mu_2) & \lambda_2 & 0 & \cdots \\ \vdots & & & & & \ddots \end{pmatrix},$$

wobei  $\lambda_n \in [0, \infty), n \geq 0$  die *Geburtsraten* und  $\mu_n \in [0, \infty), n \geq 1$  die *Sterberaten* bezeichnen. Entsprechend bezeichnen wir einen Geburts- und Todesprozess als (*reinen*) *Geburtsprozess*, falls sämtliche Sterberaten  $\mu_n = 0$  sind, beziehungsweise als (*reinen*) *Todesprozess*, falls sämtliche Geburtsraten  $\lambda_n = 0$  sind. Im letzten Fall ist  $\mathbf{Q}$  von der Gestalt

$$\mathbf{Q} = \begin{pmatrix} 0 & 0 & 0 & 0 & \cdots \\ \mu_1 & -\mu_1 & 0 & 0 & \cdots \\ 0 & \mu_2 & -\mu_2 & 0 & \cdots \\ \vdots & & & \ddots & \end{pmatrix}.$$

Insbesondere ist der Zustand 0 ein absorbierender Zustand für einen reinen Todesprozess.

### 1.3. Die minimale Konstruktion

Im Hinblick auf 1.14, stellt sich die Frage, ob auch die Umkehrung gilt, sprich, ob zu gegebener konservativer Q-Matrix  $\mathbf{Q}$  ein Markov-Prozess  $X = (X_t)_{t \geq 0}$  existiert, dessen Q-Matrix gerade durch  $\mathbf{Q}$  gegeben ist.

### 1.21 Definition

Für einen Markov-Sprungprozess  $X = (X_t)_{t \geq 0}$ , definiere die *Sprungzeiten*

$$\sigma_0 \stackrel{\text{def}}{=} 0, \quad \sigma_n \stackrel{\text{def}}{=} \inf\{t > \sigma_{n-1} : X_t \neq X_{\sigma_{n-1}}\} \quad (1.20)$$

für  $n \geq 1$ , sowie die *Absorptionszeit*

$$\varrho_A \stackrel{\text{def}}{=} \sup\{\sigma_k : \sigma_k < \infty\} \quad (1.21)$$

und die sukzessiven Eintrittszeiten in eine Menge  $A \in S$

$$\sigma_0(A) \stackrel{\text{def}}{=} 0, \quad \sigma_n(A) \stackrel{\text{def}}{=} \inf\{\sigma_k > \sigma_{n-1}(A) : X_{\sigma_{k-1}} \in A^c, X_{\sigma_k} \in A\}. \quad (1.22)$$

### 1.22 Satz

Für einen Markov-Sprungprozess  $X = (X_t)_{t \geq 0}$ , mit rechtsseitig stetigen, stückweise konstanten Pfaden sind die in (1.20) und (1.22) definierten Zufallsvariablen, sowie die *erste Explosionszeit*, definiert als  $\sigma_\infty = \sup_{n \geq 1} \sigma_n$ , Stoppzeiten.

### 1.23 Satz

Gegeben einen Markov-Sprungprozess  $X = (X_t)_{t \geq 0}$  in einem Standardmodell mit Standard-Übergangsmatrixfunktion  $(\mathbf{P}(t))_{t \geq 0}$ , konservativer Q-Matrix  $\mathbf{Q}$  und kanonischer Filtration  $\mathcal{F}$ , sei ferner vorausgesetzt, dass  $\sigma_\infty = \sup_{n \geq 1} \sigma_n = \infty$  gelte. Definiere weiter

$$\tau_n \stackrel{\text{def}}{=} (\sigma_n - \sigma_{n-1}) \mathbb{1}_{\{\sigma_{n-1} < \infty\}} + \infty \mathbb{1}_{\{\sigma_{n-1} = \infty\}} \quad (1.23)$$

$$\hat{X}_n \stackrel{\text{def}}{=} X_{\sigma_n} \mathbb{1}_{\{\sigma_n < \infty\}} + X_{\varrho_A} \mathbb{1}_{\{\sigma_n = \infty\}}. \quad (1.24)$$

Dann existiert eine Übergangsmatrix  $\hat{\mathbf{P}} = (\hat{p}_{ij})_{i,j \in S}$  mit

$$\hat{p}_{ii} = \begin{cases} 0, & \text{falls } q_i \in (0, \infty) \\ 1, & \text{falls } q_i = 0, \end{cases}$$

so dass für alle  $n \in \mathbb{N}_0$ ,  $j \in S$  und  $t \geq 0$

$$\mathbb{P}(\hat{X}_{n+1} = j, \tau_{n+1} > t | \mathcal{F}_{\sigma_n}) = \sum_{i \in S} \hat{p}_{ij} e^{-q_i t} \mathbb{1}_{\{\hat{X}_n = i\}} \quad \text{P}_\lambda\text{-f.s} \quad (1.25)$$

für alle  $\lambda \in \mathfrak{W}(S)$  gilt. Insbesondere bildet  $\hat{X}$  unter jedem  $\mathbb{P}_\lambda$  eine diskrete Markov-Kette mit Zustandsraum  $S$ , Übergangsmatrix  $\hat{\mathbf{P}}$  und Startverteilung  $\lambda$ . Ferner sind  $\tau_1, \tau_2, \dots$  bedingt unter  $\hat{X}$  stochastisch unabhängig und genügen jeweils einer Exponentialverteilung mit Parameter  $q_{\hat{X}_{n-1}}$ , das heißt  $\tau_n \sim \text{Exp}(q_{\hat{X}_{n-1}})$  für alle  $n \in \mathbb{N}$ .

**1.24 Satz**

Gegeben die Voraussetzungen des vorangegangen Satzes ist die Übergangsmatrix  $\hat{\mathbf{P}}$  der eingebetteten Markov-Kette  $(\hat{X}_n)_{n \geq 0}$  wie folgt durch  $\mathbf{Q}$  bestimmt: Falls  $0 < q_i < \infty$ , gilt

$$\hat{p}_{ii} = 0 \text{ und } \hat{p}_{ij} = q_{ij}/q_i \text{ für } i \neq j. \quad (1.26)$$

Im Fall  $q_i = 0$  gilt  $\hat{p}_{ij} = \delta_{ij}$  für alle  $j \in S$ .

Mithilfe der Sätze 1.23 und 1.24 lässt sich nunmehr zu gegebener konservativer Q-Matrix  $\mathbf{Q}$  ein Verfahren zur Konstruktion eines Markov-Sprungprozess  $X = (X_t)_{t \geq 0}$ , für den  $\mathbf{Q}$  die Q-Matrix darstellt, angeben. Man konstruiert eine diskrete Markov-Kette  $\hat{X} = (\hat{X}_n)_n$  mit Übergangsmatrix  $\hat{\mathbf{P}}$  gemäß 1.24, sowie eine Folge  $(\tau_n)_{n \geq 1}$  von exponentialverteilten Verweildauern,  $\tau_n \sim \text{Exp}(q_{\hat{X}_n})$ , die bedingt unter  $\hat{X}$  stochastisch unabhängig sind. Man definiert dann  $\sigma_0 = 0$ ,  $\sigma_n = \tau_1 + \tau_2 + \dots + \tau_n$  für die Sprungzeiten und setzt

$$X_t \stackrel{\text{def}}{=} \hat{X}_n, \text{ für alle } t \in [\sigma_n, \sigma_{n+1}) \quad (1.27)$$

und  $X_t \stackrel{\text{def}}{=} \hat{X}_n$ , falls  $\sigma_n = \infty$ . Dabei kann es allerdings passieren, dass unendlich viele Sprünge in endlicher Zeit auftreten. Man spricht in diesem Fall von *Explosion*, charakterisiert durch  $P_{\delta_i}(\sup_{n \geq 1} \sigma_n < \infty) > 0$  für ein  $i \in S$ .

Bei der *minimalen Konstruktion* wird deshalb der Zustandsraum um einen absorbierenden Punkt  $\Delta \notin S$  erweitert und der Prozess zum Explosionszeitpunkt in diesem »Friedhof« geparkt. Dies liefert dann ebenfalls einen Markov-Sprungprozess mit rechtsseitig stetigen, stückweise konstanten Pfaden.

Da Explosion in unserem Fall später nicht auftritt, verzichten wir an dieser Stelle auf diese Ausführung, notieren aber zumindest noch, warum der Begriff der minimalen Konstruktion gerechtfertigt ist, ehe wir Bedingungen an  $\mathbf{Q}$  angeben, die sicherstellen, dass die minimale Konstruktion nicht-explodierend ist.

**1.25 Satz**

Für jede zu  $\mathbf{Q}$  gehörende substochastische Standard-Übergangsmatrixfunktion  $\tilde{\mathbf{P}}(t) = (\tilde{p}_{ij}(t))_{i,j \in S}$  gilt

$$\tilde{p}_{ij}(t) \geq p_{ij}(t) \quad (1.28)$$

für alle  $i, j \in S$  und  $t \geq 0$ . Ist  $\mathbf{P}(t) = (p_{ij})_{i,j \in S}$  stochastisch, gilt also  $p_{i\Delta}(t) = 0$  für alle  $i \in S$  und  $t \geq 0$ , so ist  $\mathbf{P}(t)$  die einzige zu  $\mathbf{Q}$  gehörende substochastische Standard-Übergangsmatrixfunktion.

**1.26 Satz** (Reuters Explosionskriterium)

Die minimale Konstruktion ist genau dann nicht-explodierend, wenn  $x = 0$  die einzige nichtnegative und beschränkte Lösung der Gleichung  $\mathbf{Q}x = x$  bildet.

**1.27 Proposition**

Hinreichende Bedingungen dafür, dass die minimale Konstruktion nicht-explodierend ist, sind

- (i) Der Zustandsraum  $S$  ist endlich,
- (ii)  $\sup_{i \in S} q_i < \infty$ ,
- (iii) Die eingebettete diskrete Markovkette ist rekurrent.

## 2. ATGC's of life

Um eine Motivation für die Betrachtung von Koaleszenzbäumen zu liefern, soll nach einem oberflächlichen Einblick in die Genetik, inklusive einiger grundlegender Begriffsbildungen, auf das Wright-Fisher-Modell eingegangen werden.

Wir folgen Durrett [9] in seinem gleichnamigen Kapitel in der Feststellung, dass das Erbgut der meisten Organismen in der Desoxyribonukleinsäure (DNS) kodiert ist. Diese besteht im Regelfall aus zwei zu einer Doppelhelix verwobenen, komplementären Strängen, bestehend aus einer Sequenz aus vier verschiedenen Nukleotiden. Ein Nukleotid besteht dabei aus einer der vier verschiedenen Nukleobasen Adenin (A), Guanin (G), Cytosin (C) und Thymin (T), einer Phosphorsäure (P) und einem Zucker, im Fall der DNS, der Desoxyribose (dR). Ferner verbinden sich stets Adenin mit Thymin (über 2 Wasserstoffbrücken), sowie Cytosin mit Guanin (über drei Wasserstoffbrücken).

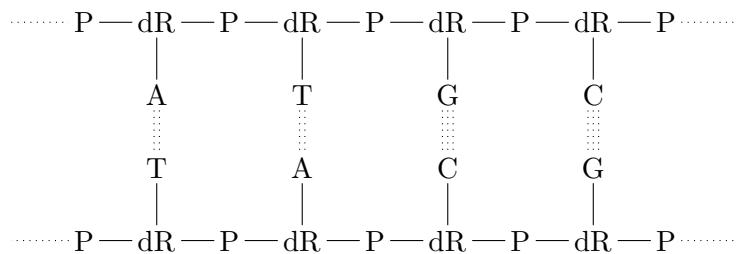


Abbildung 2.1.: Vereinfachte Darstellung eines (inneren) DNS-Abschnittes.

Das grundlegende Prinzip der Vervielfältigung von DNS besteht in der Aufteilung der Doppelhelix in zwei Stränge und der Neukonstruktion komplementärer Stränge, die durch die paarweise Bindung der Basen gegebenen sind. Auf eine genauere Darstellung des Reproduktionsverganges verzichten wir an dieser Stelle ebenfalls, fügen aber noch an, dass das Genom eines Organismus über mehrere DNS-Stränge verteilt sein kann; beim Menschen befindet sich beispielsweise ein Großteil des Erbgutes in den Zellkernen und ist dort innerhalb der Chromosomen unterteilt. Wir wollen verallgemeinert im Folgenden mit Chromosomen stets die verschiedenen DNS-Stränge eines Organismus bezeichnen.

Bevor wir nun eine einfache Variante des Wright-Fisher Modells betrachten, fassen wir zunächst noch einige Begriffe in der folgenden Definition zusammen.

## 2.1 Definition

Gegeben eine Population, bezeichnen wir diese als

- (i) *haploid*, falls die Chromosomen eines Individuums stets nur in einfacher Form vorliegen,
- (ii) *diploid*, falls die Chromosomen eines Individuums zweifach vorliegen.

Ferner bezeichnen wir eine bestimmte Ausprägung eines Gens an einem bestimmten Genort als *Allel*.

## 2.1. Das Wright-Fisher Modell

Als besonders einfache Variante des Wright-Fisher Modells wollen wir nun ein *Modell für zufällige Reproduktion ohne Mutationen und Selektion* hinsichtlich zweier Allele  $A$  und  $a$  einer haploiden Population konstanter Größe  $2N$  mit nichtüberlappenden Generationen betrachten.

Dabei lässt sich der Evolutionsprozess wie folgt mit Hilfe eines Urnenmodells beschreiben: Bezeichnen  $A_n$  beziehungsweise  $a_n$  die Anzahl der Individuen vom Typ  $A$  beziehungsweise  $a$  der  $n$ -ten Generation, so ergibt sich die  $(n+1)$ -ste Generation durch  $2N$ -faches Ziehen mit Zurücklegen aus einer Urne mit  $A_n$  Kugeln vom Typ  $A$  (und  $a_n$  Kugeln vom Typ  $a$ ).

Damit erhalten wir für die Verteilung der Anzahl der Allele vom Typ  $A$  in der  $(n+1)$ -sten Generation eine Binomialverteilung mit Parametern  $2N$  und  $p_n^{(A)} \stackrel{\text{def}}{=} A_n/2N$  gemäß der Faltungseigenschaft von Bernoulli-Verteilungen mit Parameter  $p_n^{(A)}$  (vgl. Satz 26.2 in [2]).

Dabei ist zu beachten, dass die Allel-Verteilung der  $(n+1)$ -sten Generation lediglich von der Verteilung der  $n$ -ten Generation abhängt:  $(A_n)_{n \in \mathbb{N}}$  bildet folglich einen (diskrete) Markov-Kette.

Vermöge des Urnenmodells für den Generationswechsel, notieren wir ferner die offensichtliche Feststellung, dass 0 und  $2N$  absorbierende Zustände für  $(A_n)_{n \in \mathbb{N}}$  darstellen. Darüber hinaus stellen wir fest, dass einer dieser Zustände nach hinreichend langer Zeit angenommen wird.

In natürlicher Weise stellt sich damit die Frage, wie lange es dauert, bis ein Allel ausgestorben ist.

Wir folgen weiter [9] und bezeichnen mit

$$H_n^\circ = \frac{2A_n(2N - A_n)}{2N(2N - 1)}$$

die Wahrscheinlichkeit, dass zwei zufällig gewählte Individuen (Ziehen ohne Zurücklegen) zum Zeitpunkt  $n$  von unterschiedlichem Typ sind. In Anlehnung an diploide Organismen, bei denen Heterozygotie (in Bezug auf ein bestimmtes Gen) bedeutet, dass im Chromosomensatz zwei verschieden Allele vorliegen, nennt man  $H_n^\circ$  die *Heterozygotie* einer Population.

Wir notieren ohne Beweis:

## 2.2 Satz

In einem haploiden Modell für zufällige Reproduktion ohne Mutationen und Selektion hinsichtlich zweier Allele einer Population konstanter Größe  $2N$  gilt für die Heterozygotität  $H_n^\circ$  der Population zum Zeitpunkt  $n$

$$EH_n^\circ = \left(1 - \frac{1}{2N}\right)^n EH_0^\circ.$$

Diese Beziehung gilt auch, wenn man in der Definition der Heterozygotie ohne Zurücklegen zieht. Das heißt, wenn man

$$H_n = \frac{2A_n(2N - A_n)}{(2N)^2} = \frac{2N - 1}{2N} H_n^\circ$$

setzt, so gilt  $EH_n = (1 - 1/2N)^n EH_0$ .

Mit Verweis auf §8, Satz 2 in [11] erhalten wir aus der Reihendarstellung der Exponentialfunktion

$$e^{-x} = 1 - x + R(x), \text{ mit } |R(x)| \leq x^2,$$

für alle  $x$  mit  $|x| \leq 3/2$ .

Dies liefert für hinreichend großes  $2N$  die asymptotische Beziehung

$$EH_n \approx e^{-n} EH_0$$

## 2.3 Bemerkung

Das beschriebene Urnenmodell lässt sich leicht um Abstammungsinformationen erweitern: Dazu macht man die Kugeln der Anfangsgeneration unterscheidbar, beispielsweise durch (zufällige) Durchnummerierung von 1 bis  $2N$ . Wir können dann ein Individuum der  $(n + 1)$ -sten Generation als Kind eines Individuums der  $n$ -ten Generation identifizieren. Dementsprechend bezeichnen wir mit einer *Ahnenlinie* die aufsteigende Linie der Vorfahren eines Individuums der  $n$ -ten Generation.

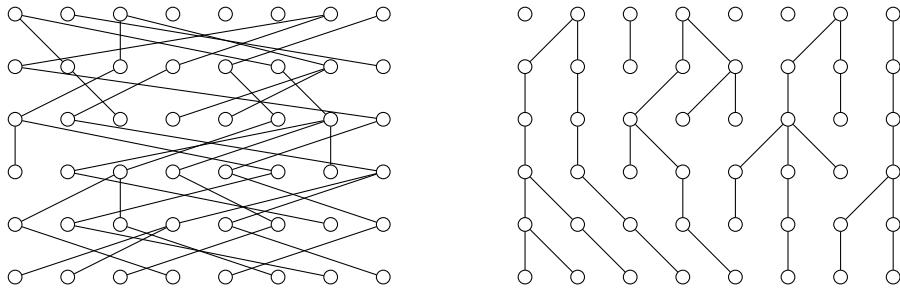


Abbildung 2.2.: Realisierung des Wright-Fisher Modells für eine Population der Größe 8 über 6 Generationen mit eingetragenen Ahnenlinien (links) und einer »entworfenen« Version (rechts).

## 2.4 Satz

Unter Reskalierung der Zeit bezüglich  $2N$  Generationen genügt die Zeit  $\tau_k$ , für die  $k$  verschiedene Ahnenlinien existieren, einer Exponentialverteilung mit Parameter  $\binom{k}{2}$ .

*Beweis.* Wir vermerken zunächst, dass bei der Betrachtung von Ahnenlinien, also der Be- trachtung eines Wright-Fisher Modells in rückwärtiger Zeit, diese lediglich verschmelzen können. Dies ist der Fall, wenn wenigstens zwei Individuen einen direkten gemeinsamen Vorfahren haben.

Wir betrachten deshalb zunächst die Wahrscheinlichkeit, dass  $k$  Individuen einer Generation verschiedene Eltern haben. Dazu erinnern wir an den Generationswechsel und notieren, dass nach Ziehen von  $m$  verschiedenen Kugeln noch  $2N - m$  davon verschiedene Kugeln existieren. Damit berechnet sich die gewünschte Wahrscheinlichkeit zu

$$\prod_{i=0}^{k-1} \frac{2N - i}{2N} = \prod_{i=1}^{k-1} \left(1 - \frac{i}{2N}\right) = 1 - \frac{\sum_{i=0}^{k-1} i}{2N} + \mathcal{O}\left(\frac{1}{N^2}\right),$$

wobei im letzten Schritt das Produkt ausmultipliziert und nach den Potenzen von  $2N$  umsortiert wurde (vgl. auch [16]). Für die Wahrscheinlichkeit, dass  $k$  Ahnenlinien über die ersten  $n$  Generationen bestehen bleiben, erhalten wir daher

$$\left(1 - \frac{k(k-1)}{2} \cdot \frac{1}{2N} + \mathcal{O}\left(\frac{1}{N^2}\right)\right)^n$$

Reskalieren wir also die Zeit mit  $2N$ , setzen wir also  $t \stackrel{\text{def}}{=} n/2N$ , so erhalten wir

$$\lim_{N \rightarrow \infty} \left(1 - \frac{k(k-1)}{2} \cdot \frac{1}{2N} + \mathcal{O}\left(\frac{1}{N^2}\right)\right)^{2Nt} = \exp\left(-\frac{k(k-1)}{2}t\right)$$

und damit für die skalierte Zeit bis zum ersten Verschmelzungereignis eine exponentiellverteilte Zeit mit Parameter  $\binom{k}{2}$ .

Mit der Feststellung, dass die obige Argumentation für jeden Zeitpunkt, zu dem  $k$  Ahnenlinien existieren, greift, folgt damit die Behauptung.  $\square$

Für die Wahrscheinlichkeit, dass mehr als zwei Individuen dieselben Eltern haben, notieren wir, dass diese in  $\mathcal{O}(\frac{1}{N^2})$  liegt und mithin ebenfalls asymptotisch vernachlässigbar ist. Dazu überlegen wir uns, dass die Wahrscheinlichkeit, dass es ein Individuum der Vorgängergeneration mit mindestens 3 Kindern gibt, durch  $2N\binom{k}{3}(\frac{1}{2N})^3 \in \mathcal{O}(\frac{1}{N^2})$  gegeben ist.

### 2.5 Bemerkung

Unter den Annahmen von 2.4 verschmelzen  $k$  verschiedene Ahnenlinien nach einer exponentiellverteilten Zeit  $\tau_k$  mit Parameter  $\binom{k}{2}$  zu  $(k-1)$  verschiedenen Ahnenlinien.

Vermöge der Feststellung, dass sich in einem Modell zufälliger Reproduktion ohne Mutation und Selektionsdruck hinsichtlich zweier Allele einer diploiden Population konstanter Größe  $N$ , jedes Gen zu jedem Zeitpunkt eindeutig zurückverfolgen lässt, kann man dieses auch als Modell für eine haploide Population konstanter Größe  $2N$  betrachten.

Zu beachten ist allerdings, dass bei dieser Betrachtungsweise auch Selbstbefruchtung zu berücksichtigen ist. Mit Bezug auf (14) in [16] notieren wir allerdings, dass für einen geeignet gewählten Skalierungsparameter  $2N_e = 2N/(1+F)$ , wobei  $F$  abhängig von der Wahrscheinlichkeit für Selbstbefruchtung ist, die Ahnenlinien sich gemäß der obigen Bemerkung verhalten.

Ähnlich erhält man für eine zweigeschlechtliche, diploide Population der Größe  $N$  mit  $N_m$  männlichen und  $N_f$  weiblichen Individuen, also  $N = N_m + N_f$ , einen Skalierungsparameter  $2N_e = 8N_mN_f/(N_m + N_f)$ , bezüglich dem die Ahnenlinien sich asymptotisch erneut gemäß der obigen Bemerkung verhalten (vgl (16) in [16]).

### 3. Der Koaleszenzprozess nach Kingman

Wir haben gesehen, dass für eine haploide Population der Größe  $2N$ , beziehungsweise alternativ für eine diploide Population der Größe  $N$  mit zufälliger Rekombination, ohne Mutation und Selektionsdruck, die Zeit, bis  $k$  Ahnenlinien zu  $k - 1$  Ahnenlinien verschmelzen, asymptotisch gemäß einer Exponentialverteilung mit Parameter  $\binom{k}{2}$  verhält. Kingman [14],[15] definierte 1982 den  $n$ -Koaleszenzprozess als zeitstetige Markov-Kette auf den Äquivalenzrelationen von  $\{1, 2, \dots, n\}$  als Approximation der Genealogie einer (haploiden) Population unter dem Wright-Fisher-Modell.

Bemerkenswert ist dabei, dass die Betrachtung zeitlich rückwärts stattfindet und lediglich die Genealogie einer Population und nicht die expliziten genetischen Strukturen jeder Generation betrachtet. Insbesondere werden bereits ausgestorbene Erblinien nicht betrachtet, was im Hinblick auf Simulationsverfahren auch den Rechenaufwand reduziert.

#### 3.1. Der $n$ -Koaleszenzprozess

In diesem Abschnitt sei stets  $n \in \mathbb{N}$  eine natürliche Zahl. Ferner sei, sofern nicht anders angegeben, stets  $(\Omega, \mathfrak{A}, P)$  ein Wahrscheinlichkeitsraum.

**3.1 Definition** (i)  $\mathcal{E}_n$  bezeichne die Menge der Äquivalenzrelationen auf  $\{1, 2, \dots, n\}$ .

(ii) Die Äquivalenzrelationen  $\Delta_n, \Theta_n \in \mathcal{E}_n$  seien durch

$$\Delta_n \stackrel{\text{def}}{=} \{(i, i) | i \in \{1, 2, \dots, n\}\}, \quad (3.1)$$

$$\Theta_n \stackrel{\text{def}}{=} \{(i, j) | i, j \in \{1, 2, \dots, n\}\} \quad (3.2)$$

gegeben. Dann ist  $\Delta_n$  die Äquivalenzrelation, in der jedes Element aus  $\{1, 2, \dots, n\}$  nur mit sich selbst äquivalent ist und  $\Theta_n$  die Äquivalenzrelation, in der alle Elemente aus  $\{1, 2, \dots, n\}$  miteinander äquivalent sind.

(iii) Für  $\xi \in \mathcal{E}_n$  bezeichne  $|\xi|$  die Anzahl der Äquivalenzklassen von  $\xi$ . Darüber hinaus bezeichne für  $k < l \leq n$

$$k \sim_{\xi} l \stackrel{\text{def}}{\Leftrightarrow} (k, l) \in \xi$$

die Äquivalenz von  $k$  und  $l$  bezüglich  $\xi$ , sowie  $[k]$  die Äquivalenzklasse von  $k$ .

- (iv) Für  $\xi, \eta \in \mathcal{E}_n$  bezeichne  $\xi \prec \eta$ , dass  $\eta$  aus  $\xi$  durch das Verschmelzen zweier Äquivalenzklassen hervorgeht, also dass

$$\xi \prec \eta \Leftrightarrow \xi \subset \eta, \quad |\xi| = |\eta| + 1 \quad (3.3)$$

gilt.

Wir folgen nun Kingman in der Definition des  $n$ -Koaleszenzprozesses in [14].

### 3.2 Definition

Ein Markov-Sprungprozess  $(R_t)_{t \geq 0}$  mit Zustandsraum  $\mathcal{E}_n$  heißt  $n$ -Koaleszenzprozess, falls

$$R_0 = \Delta_n \quad (3.4)$$

gilt und die Übergangsraten

$$q_{\xi\eta} = \lim_{h \downarrow 0} h^{-1} P(R_{t+h} = \eta | R_t = \xi)$$

mit  $\xi, \eta \in \mathcal{E}_n, \xi \neq \eta$  durch

$$q_{\xi\eta} = \begin{cases} 1 & \text{falls } \xi \prec \eta, \\ 0 & \text{sonst} \end{cases} \quad (3.5)$$

gegeben sind.

Damit nun  $\mathbf{Q} \stackrel{\text{def}}{=} (q_{\xi\eta})_{\xi,\eta}$  konservativ wird, ergibt sich für die Diagonaleinträge unweigerlich:

### 3.3 Korollar

Es sei  $(R_t)_{t \geq 0}$  ein  $n$ -Koaleszenzprozess und  $\xi \in \mathcal{E}_n$ . Für die Gesamtaustrittsrate

$$q_\xi = \lim_{h \downarrow 0} h^{-1} P(R_{t+h} \neq \xi | R_t = \xi) = \sum_{\eta \neq \xi} q_{\xi\eta}$$

aus  $\xi$  gilt

$$q_\xi = \frac{1}{2} |\xi| (|\xi| - 1). \quad (3.6)$$

*Beweis.* Die einzigen Zustände  $\eta \neq \xi$ , für die der Summand ungleich 0 ist, sind definitiengemäß alle  $\eta$  mit  $\xi \prec \eta$ , also diejenigen  $\eta$ , welche aus  $\xi$  durch die Verschmelzung zweier

Äquivalenzklassen von  $\xi$  hervorgehen. Dies entspricht der Auswahl aller 2-elementigen Teilmengen aus einer  $|\xi|$ -elementigen Menge. Damit gilt

$$q_\xi = \sum_{\eta \neq \xi} q_{\xi\eta} = \sum_{\xi \prec \eta} q_{\xi\eta} = \sum_{\xi \prec \eta} 1 = \binom{|\xi|}{2} = \frac{1}{2}|\xi|(|\xi| - 1)$$

für alle  $\xi \in \mathcal{E}_n$ . □

### 3.4 Bemerkung

Solche Markov-Sprungprozesse existieren und besitzen alle dieselben endlich-dimensionalen Verteilungen. Darüber hinaus können diese so konstruiert werden, dass ihre Pfade rechtsseitig stetig und stückweise konstant sind.

Vermöge der Verteilungs-Eindeutigkeit, ist es mitunter auch üblich, von *dem*  $n$ -Koaleszenzprozess zu reden.

*Beweis.* Wir beginnen mit der Feststellung, dass  $\mathcal{E}_n$  versehen mit der diskreten Topologie insbesondere polnisch ist. Ferner haben wir  $\mathbf{Q}$  gerade so gewählt, dass  $\mathbf{Q}$  konservativ ist. Mit Hinweis auf 1.27 folgt wegen der Endlichkeit des Zustandsraumes damit die Eindeutigkeit der minimalen Konstruktion. Speziell gilt für die Übergangsmatrixfunktion  $(\mathbf{P}(t))_{t \geq 0}$

$$\mathbf{P}_t = e^{\mathbf{Qt}} \stackrel{\text{def}}{=} \sum_{k=0}^{\infty} \frac{t^k}{k!} \mathbf{Q}^k,$$

für  $t \geq 0$  (vgl. Korollar 3.5 in [3]). □

Insbesondere gilt vermöge 1.18, dass  $n$ -Koaleszenzprozesse (mit rechtsseitig stetigen und stückweise konstanten Pfaden) die starke Markov-Eigenschaft besitzen.

### 3.5 Bemerkung

Sei  $(R_t)_{t \geq 0}$  ein  $n$ -Koaleszenzprozess und  $\xi \in \mathcal{E}_n$  mit  $|\xi| = k$  für ein  $k \in \mathbb{N}$ , dann ist die Verweildauer in  $\xi$  exponentialverteilt mit Parameter  $d_k = \frac{1}{2}k(k-1)$  und hängt somit einzig von  $|\xi|$  ab.

*Beweis.* Aufgrund der Markov-Eigenschaft ist klar, dass die Verweildauer eine gedächtnislose Verteilung haben muss und die einzige zeitstetige gedächtnislose Verteilung ist die Exponentialverteilung. Mit Gleichung (3.6) folgt schließlich die Behauptung. □

### 3.6 Definition und Satz

Gegeben einen  $n$ -Koaleszenzprozess  $(R_t)_{t \geq 0}$ , definieren wir

$$D_t \stackrel{\text{def}}{=} |R_t|. \tag{3.7}$$

Dann ist  $(D_t)_{t \geq 0}$  eine zeitstetige Markov-Kette mit Zustandsraum  $\{1, 2, \dots, n\}$  und Übergangsraten

$$\lim_{h \downarrow 0} h^{-1} P(D_{t+h} = l | D_t = k) = \begin{cases} d_k & \text{falls } l = k - 1, \\ 0 & \text{falls } l \neq k, k - 1, \end{cases} \quad (3.8)$$

mit  $d_k = \frac{1}{2}k(k - 1)$ .

*Beweis.* Sei  $\xi \in \mathcal{E}_n$ . Für jeden Zustandswechsel von  $\xi$  in einen Zustand  $\eta \in \mathcal{E}_n$  muss gemäß Definition  $|\eta| = |\xi| - 1$  gelten. Jeder Zustandswechsel in  $(R_t)_{t \geq 0}$  entspricht also genau einem Zustandswechsel in  $(D_t)_{t \geq 0}$  und umgekehrt. Der Prozess  $(D_t)_{t \geq 0}$  verhält sich also in seiner Sprungdynamik wie der Koaleszenzprozess und ist mithin selbst ein Markov-Sprungprozess. Die Übergangsrate von einem Zustand  $k$  in einen Zustand  $k - 1$  in  $(D_t)_{t \geq 0}$  korrespondiert demnach mit den Austrittsraten  $q_\xi$  aus einem Zustand  $\xi$  mit  $|\xi| = k$  im Koaleszenzprozess.

Sei  $(R_t)_{t \geq 0}$  ein  $n$ -Koaleszenzprozess und  $(D_t)_{t \geq 0}$  gemäß 3.6 definiert. Sei ferner  $\omega \in \Omega$  und gelte  $D_t(\omega) = k$ . Dann gibt es ein  $\xi(\omega) \in \mathcal{E}_n$  mit  $|\xi(\omega)| = k$  und  $R_t(\omega) = \xi(\omega)$ . Seien ferner  $k, l \in \{1, 2, \dots, n\}$ , dann gilt:

$$\begin{aligned} & \lim_{h \downarrow 0} h^{-1} P(D_{t+h}(\omega) = l | D_t(\omega) = k) \\ &= \lim_{h \downarrow 0} h^{-1} P(D_{t+h}(\omega) = l | R_t(\omega) = \xi(\omega)) \\ &= \lim_{h \downarrow 0} h^{-1} \sum_{\substack{\eta(\omega) \in \mathcal{E}_n \\ |\eta(\omega)| = l}} P(R_{t+h}(\omega) = \eta(\omega)) | R_t(\omega) = \xi(\omega)) \end{aligned}$$

Für  $l = k - 1$  bedeutet dies gerade  $q_\xi(\omega)$  und für  $l \neq k, k - 1$  sind die einzelnen Summanden = 0.  $\square$

In der üblichen Terminologie (vgl. 1.20) handelt es sich bei  $(D_t)_{t \geq 0}$  um einen reinen Todesprozess mit Anfangszustand  $n$  und Sterberaten  $d_k$ .

Darüber hinaus ist die in 3.1 definierte Äquivalenzrelation  $\Theta$  ein absorbierender Zustand für  $(R_t)_{t \geq 0}$  und dazu korrespondierend der Zustand 1 für  $(D_t)_{t \geq 0}$  absorbierend.

### 3.7 Proposition

Sei  $(R_t)_{t \geq 0}$  ein  $n$ -Koaleszenzprozess und  $(D_t)_{t \geq 0}$  der assoziierte Todesprozess gemäß 3.6. Es bezeichne  $\tau_k$  die Verweildauer von  $(D_t)_{t \geq 0}$  im Zustand  $k$  für alle  $k \in \{2, \dots, n\}$ .

- (i) Dann sind die  $\tau_k$  unabhängig und jeweils gemäß einer Exponentialverteilung mit Parameter  $d_k = \frac{1}{2}k(k - 1)$  verteilt, das heißt  $\tau_k \sim \text{Exp}(d_k)$ .

(ii) Die Durchgangszeit

$$T \stackrel{\text{def}}{=} \inf\{t \geq 0 | R_t = \Theta\} = \inf\{t \geq 0 | D_t = 1\}$$

kann mittels der  $\tau_k$  als

$$T = \sum_{k=2}^n \tau_k$$

dargestellt werden.

*Beweis.* zu (i) Analog zu 3.5 liefert auch hier die Markov-Eigenschaft zusammen mit den Übergangsraten von  $(D_t)_{t \geq 0}$ , dass die  $\tau_k$  jeweils exponentialverteilt mit Parameter  $d_k$  sind. Ebenfalls liefert die Markov-Eigenschaft die Unabhängigkeit vermöge der Feststellung, dass die Aufenthaltsdauer in einem Zustand unabhängig vom Eintrittszeitpunkt ist.  $\square$

Ein typischer Pfad von  $(R_t)_{t \geq 0}$  ist nun eine Folge von Äquivalenzrelationen

$$\Delta = \mathcal{R}_n \prec \mathcal{R}_{n-1} \prec \mathcal{R}_{n-2} \prec \cdots \prec \mathcal{R}_2 \prec \mathcal{R}_1 = \Theta, \quad (3.9)$$

wobei der Prozess jeweils eine  $\text{Exp}(d_k)$ -verteilte Zeit  $\tau_k$  in  $\mathcal{R}_k$  verbringt. Offensichtlich gilt

$$|\mathcal{R}_k| = k. \quad (3.10)$$

Die Folge (3.9) entspricht einem typischen Pfad der eingebetteten diskreten Markovkette des  $n$ -Koaleszenzprozesses, auch Sprung-Kette genannt.

## 3.2. Die Sprung-Kette

### 3.8 Satz

Es sei  $(R_t)_{t \geq 0}$  ein  $n$ -Koaleszenzprozess und  $(D_t)_{t \geq 0}$  der assoziierte Todesprozess, sowie  $(\mathcal{R}_k)_{k=n,n-1,\dots,1}$  die eingebettete diskrete Markovkette. Dann sind  $(\mathcal{R}_k)_{k=n,n-1,\dots,1}$  und  $(D_t)_{t \geq 0}$  unabhängig und es gilt

$$R_t = \mathcal{R}_{D_t} \quad (3.11)$$

für alle  $t \geq 0$ . Die Übergangswahrscheinlichkeiten der Markov-Kette  $(\mathcal{R}_k)$  sind für  $\xi \in \mathcal{E}_n$ ,  $|\xi| = k$  und  $2 \leq k \leq n$  durch

$$P(\mathcal{R}_{k-1} = \eta | \mathcal{R}_k = \xi) = \begin{cases} \frac{2}{k(k-1)} & \text{falls } \xi \prec \eta, \\ 0 & \text{sonst,} \end{cases} \quad (3.12)$$

gegeben. Die absoluten Wahrscheinlichkeiten sind durch

$$P(\mathcal{R}_k = \xi) = \frac{(n-k)!k!(k-1)!}{n!(n-1)!} \lambda_1! \lambda_2! \cdots \lambda_k!, \quad (3.13)$$

gegeben, wobei  $\lambda_1, \lambda_2, \dots, \lambda_k$  die Größen der Äquivalenzklassen von  $\xi$  bezeichne.

*Beweis.* Gemäß der Theorie über Sprung-Ketten (vgl. 1.24), sind die Übergangswahrscheinlichkeiten von der Form

$$\frac{q_{\xi\eta}}{q_\xi} \quad (\xi \neq \eta),$$

sofern  $q_\xi > 0$  gilt. Zudem sind die Verweildauern bedingt unter der Sprung-Kette unabhängig und exponentialverteilt mit Parameter  $q_\xi$ .

Es gilt also für  $\xi, \eta \in \mathcal{E}_n$ ,  $|\xi| = k$  und  $\xi \prec \eta$

$$P(\mathcal{R}_{k-1} = \eta | \mathcal{R}_k = \xi) = \frac{q_{\xi\eta}}{q_\xi} = q_\xi^{-1} = \frac{2}{|\xi|(|\xi| - 1)}$$

und damit (3.12) unter Berücksichtigung von (3.10).

Für den Beweis von (3.13) führen wir eine Rückwärtsinduktion über  $k$  durch. Führe dafür zunächst die abkürzende Schreibweise

$$p_k(\xi) \stackrel{\text{def}}{=} P(\mathcal{R}_k = \xi), \quad \xi \in \mathcal{E}_n, |\xi| = k$$

ein. Für den Fall  $k = n$  ist die Aussage offensichtlich richtig, denn in diesem Fall folgt schon  $\xi = \Delta_n$  und damit

$$1 = p_n(\Delta_n) = \frac{(n-n)!n!(n-1)!}{n!(n-1)!} \underbrace{1! \cdots 1!}_{=\lambda_1! \cdots \lambda_n!} = 1$$

Gemäß (3.12) gilt ferner für  $\eta \in \mathcal{E}_n$

$$p_{k-1}(\eta) = \sum_{\xi \prec \eta} \frac{2}{k(k-1)} p_k(\xi),$$

denn:

$$\begin{aligned} P(\mathcal{R}_{k-1} = \eta) &= \sum_{\xi \prec \eta} P(\mathcal{R}_k = \xi) P(\mathcal{R}_{k-1} = \eta | \mathcal{R}_k = \xi) \\ &= \sum_{\xi \prec \eta} \frac{2}{|\xi|(|\xi| - 1)} P(\mathcal{R}_k = \xi) \end{aligned}$$

Wenn nun  $\lambda_1, \lambda_2, \dots, \lambda_{k-1}$  die Größen der Äquivalenzklassen von  $\eta$  bezeichnen, sind die von  $\xi$  gerade  $\lambda_1, \lambda_2, \dots, \lambda_{l-1}, \nu, \lambda_l - \nu, \lambda_{l+1}, \dots, \lambda_{k-1}$  für ein  $l, 1 \leq l \leq k-1$  und ein  $\nu, 1 \leq \nu \leq \lambda_l - 1$ . Nehmen wir nun also an, die Aussage sei bereits für  $k$  bewiesen, so müssen wir, um über alle möglichen  $\xi$  aus unserer Rekursionsgleichung aufzusummen, über alle möglichen Indizes  $l$  und alle Möglichkeiten, die  $l$ -te Äquivalenzklasse von  $\eta$  auf zwei verschiedene Klassen aufzuteilen, aufzusummen. Für jedes  $1 \leq \nu \leq \lambda_l - 1$  gibt es dann  $\binom{\lambda_l}{\nu} = \frac{\lambda_l!}{\nu!(\lambda_l - \nu)!}$  Möglichkeiten,  $\nu$  Elemente aus der  $l$ -ten Äquivalenzklasse von  $\eta$  für eine neue Klasse zu entnehmen. Nun vertauschen aber die Rollen der  $\nu$ -ten und der  $l$ -ten Klasse miteinander, weshalb dies mit einem Faktor von  $\frac{1}{2}$  korrigiert werden muss. In Formeln geschrieben gilt dann

$$\begin{aligned}
 & p_{k-1}(\eta) \\
 &= \sum_{l=1}^{k-1} \sum_{\nu=1}^{\lambda_l-1} \frac{2}{k(k-1)} \frac{(n-k)!k!(k-1)!}{n!(n-1)!} \lambda_1! \dots \lambda_{l-1}! \nu! (\lambda_l - \nu)! \lambda_{l+1}! \dots \lambda_{k-1}! \frac{1}{2} \binom{\lambda_l}{\nu} \\
 &= \frac{(n-k)!(k-1)!(k-2)!}{n!(n-1)!} \sum_{l=1}^{k-1} \lambda_1! \dots \lambda_{l-1}! \lambda_{l+1}! \dots \lambda_{k-1}! \sum_{\nu=1}^{\lambda_l-1} \binom{\lambda_l}{\nu} (\lambda_l - \nu)! \nu! \\
 &= \frac{(n-k)!(k-1)!(k-2)!}{n!(n-1)!} \sum_{l=1}^{k-1} \lambda_1! \dots \lambda_{l-1}! \lambda_{l+1}! \dots \lambda_{k-1}! \sum_{\nu=1}^{\lambda_l-1} \frac{\lambda_l! (\lambda_l - \nu)! \nu!}{(\lambda_l - \nu)! \nu!} \\
 &= \frac{(n-k)!(k-1)!(k-2)!}{n!(n-1)!} \sum_{l=1}^{k-1} \lambda_1! \dots \lambda_{l-1}! \lambda_l! \lambda_{l+1}! \dots \lambda_{k-1}! \sum_{\nu=1}^{\lambda_l-1} 1 \\
 &= \frac{(n-k)!(k-1)!(k-2)!}{n!(n-1)!} \lambda_1! \lambda_2! \dots \lambda_{k-1}! \sum_{l=1}^{k-1} \sum_{\nu=1}^{\lambda_l-1} 1. \tag{3.14}
 \end{aligned}$$

Die Doppelsumme in (3.14) berechnet sich ferner zu

$$\sum_{l=1}^{k-1} \sum_{\nu=1}^{\lambda_l-1} 1 = \sum_{l=1}^{k-1} (\lambda_l - 1) = \sum_{l=1}^{k-1} \lambda_l - \sum_{l=1}^{k-1} 1 = n - (k-1),$$

womit der Induktionsschritt bewiesen ist.  $\square$

### 3.9 Satz

Gegeben ein  $n$ -Koaleszenzprozess  $(R_t)_{t \geq 0}$  mit assoziierter Sprungkette  $(\mathcal{R}_k)_k$ , sowie  $l < k, \xi, \eta \in \mathcal{E}_n, |\xi| = k, |\eta| = l, \xi \subset \eta$ , gilt für die bedingten Verteilungen von  $\mathcal{R}_k$

$$\mathbb{P}(\mathcal{R}_l = \eta | \mathcal{R}_k = \xi) = \frac{(k-l)!l!(l-1)!}{k!(k-1)!} \lambda_1! \lambda_2! \dots \lambda_l!, \tag{3.15}$$

wobei  $\lambda_1, \lambda_2, \dots, \lambda_l$  wie folgt definiert sind: Seien  $\eta_i, 1 \leq i \leq l$  die Äquivalenzklassen von  $\eta$  und  $\xi_j, 1 \leq j \leq k$  die Äquivalenzklassen von  $\xi$ , so ist  $\lambda_i$  die Anzahl der Äquivalenzklassen von  $\xi$ , welche zu  $\eta_i$  verschmelzen, das heißt

$$\lambda_i = |\{\xi_j \mid 1 \leq j \leq k, \xi_k \subset \eta_i\}|.$$

*Beweis.* Wir verzichten an dieser Stelle auf einen Beweis, merken aber an, dass man einen Beweis führen kann, wenn man die Äquivalenzklassen von  $\xi$  als Individuen eines nunmehr  $|\xi|$ -Koaleszenzprozesses auffasst. Dieser Idee werden wir im folgenden Abschnitt weiter nachgehen und verweisen deshalb an dieser Stelle auf das noch ausstehende Ergebnis 3.11.  $\square$

### 3.3. Der Koaleszenzprozess

Nachdem wir nun den  $n$ -Koaleszenzprozess für beliebige natürliche Zahlen  $n$  kennengelernt haben, stellt sich hinsichtlich tieferer Analysen, wie zum Beispiel Grenzwertverhalten von  $n$ -Koaleszenzprozessen, die Frage, inwiefern Koaleszenzprozesse für verschiedene  $n$  in Verbindung stehen. In den Kapiteln 6 und 7 in [15], stellt Kingman zwei verschiedene Konzepte der Einbettung eines  $m$ -Koaleszenzprozesses in einen  $n$ -Koaleszenzprozess vor, *Temporal Coupling* beziehungsweise *Natural Coupling*. Als Konsequenz dieser Konsistenz-eigenschaft ergibt sich darüber hinaus sogar die Existenz eines Prozesses  $(R_t)_{t \geq 0}$  auf der Menge  $\mathcal{E}$  der Äquivalenzklassen auf den natürlichen Zahlen, so dass dieser  $n$ -Koaleszenzprozesse für alle  $n \in \mathbb{N}$  enthält (vgl. Kapitel 8 in [15], oder [14]).

#### 3.10 Bemerkung

Es sei  $\xi \in \mathcal{E}_n$  eine Äquivalenzrelation mit Äquivalenzklassen  $\xi_1, \xi_2, \dots, \xi_k$ . Wir vermerken zunächst, dass wir die Äquivalenzklassen nach der natürlichen Ordnung ihrer kleinsten Elementen sortieren können, das heißt, wir schreiben

$$\xi_i \leq \xi_j \stackrel{\text{def}}{\iff} \min\{k : k \in \xi_i\} \leq \min\{k : k \in \xi_j\},$$

wobei wir  $\min \emptyset \stackrel{\text{def}}{=} \inf$  setzen. Dann können wir jede Äquivalenzrelation in  $\mathcal{E}_n$  als  $n$ -Tupel  $(\nu_1, \nu_2, \dots, \nu_n)$  darstellen, mit  $\nu_i < \nu_j$  für alle  $0 < i < j \leq |\xi|$  und  $\nu_k = \emptyset$  für  $k > |\xi|$ .

#### 3.11 Proposition (Temporal Coupling)

Es sei  $(R_t^{(n)})_{t \geq 0}$  ein  $n$ -Koaleszenzprozess und  $(D_t)_{t \geq 0}$  der assoziierte Todesprozess. Es bezeichne  $\tau_k$  die Verweildauer von  $(D_t)_{t \geq 0}$  im Zustand  $k$ . Setze  $T_k \stackrel{\text{def}}{=} \sum_{i=0}^{k-1} \tau_{n-i}$ . Definiere

ferner eine Abbildung  $\kappa_{m,n} : \mathcal{E}_n \rightarrow \mathcal{E}_m$  gemäß

$$\kappa_{m,n}(\xi_1, \xi_2, \dots, \xi_n) = ([1], [2], \dots, [\lceil \xi \rceil], \emptyset, \dots, \emptyset),$$

wobei  $(\xi_1, \xi_2, \dots, \xi_n)$  die in 3.10 vorgestellte Darstellung bezeichnet. Dann gilt

$$(\kappa_{m,n} R_{T_m+t}^{(n)})_{t \geq 0} \stackrel{d}{=} (R_t^{(m)})_{t \geq 0}$$

für einen  $m$ -Koaleszenzprozess  $(R_t^{(m)})_{t \geq 0}$ , das heißt  $(\kappa_{m,n} R_{T_m+t})_{t \geq 0}$  ist ein  $m$ -Koaleszenzprozess.

*Beweis.* Wir beginnen mit der Feststellung, dass es ausreichend ist, die Behauptung für den Übergang  $n \rightarrow (n-1)$  zu zeigen. Bezeichne also  $\tau_n = \inf\{t > 0 : R_t \neq R_0\}$  die erste Sprungzeit und  $\kappa \stackrel{\text{def}}{=} \kappa_{n-1,n}$ . Vermöge der starken Markov-Eigenschaft ist  $(R'_t)_{t \geq 0} \stackrel{\text{def}}{=} (R_{\tau_n+t})_{t \geq 0}$  ein Markov-Sprungprozess mit derselben Sprungdynamik wie  $(R_t)_{t \geq 0}$ , gestartet in  $R_{\tau_n}$ . Offensichtlich gilt  $R'_0 = \Delta_m$  und jeder Sprung von  $(R'_t)_{t \geq 0}$  induziert einen Sprung von  $(\kappa R'_t)_{t \geq 0} = (\kappa R_{\tau_n+t})_{t \geq 0}$ .  $\square$

Rein anschaulich kann man also für  $m < n$  einen  $m$ -Koaleszenzprozess innerhalb eines  $n$ -Koaleszenzprozesses  $(R_t)_{t \geq 0}$  finden, indem man bis zu dem Zeitpunkt wartet, an dem  $(R_t)_{t \geq 0}$  aus  $m$  Äquivalenzklassen besteht, und dann diese als Individuen auffasst.

Im Hinblick auf den  $n$ -Koaleszenzprozess als Modell für die Genealogie einer Auswahl von  $n$  Individuen einer Population der Größe  $2N$ , ist es allerdings natürlicher, statt  $n$  Individuen eine Subpopulation von  $m < n$  Individuen zu betrachten. In Bezug zu einem  $n$ -Koaleszenzprozess bedeutet dies die Einschränkung auf die Äquivalenzrelationen auf  $m$  Elementen. Die positive Antwort, dass auch auf diese Art ein  $m$ -Koaleszenzprozess innerhalb eines  $n$ -Koaleszenzprozesses gefunden werden kann, liefert nunmehr

### 3.12 Proposition (Natural Coupling)

Sei  $(R_t^{(n)})_{t \geq 0}$  ein  $n$ -Koaleszenzprozess, sowie  $m < n$ ,  $m, n \in \mathbb{N}$ . Sei ferner  $\rho_{m,n} : \mathcal{E}_n \rightarrow \mathcal{E}_m$  definiert durch

$$\rho_{m,n}(\xi) \stackrel{\text{def}}{=} \{(i, j) \mid 1 \leq i, j \leq m, (i, j) \in \xi\}$$

für alle  $\xi \in \mathcal{E}_n$ . Dann ist  $(\rho_{m,n} R_t^{(n)})_{t \geq 0}$  ein  $m$ -Koaleszenzprozess, das heißt

$$(\rho_{m,n} R_t^{(n)})_{t \geq 0} \stackrel{d}{=} (R_t^{(m)})_{t \geq 0} \tag{3.16}$$

für einen  $m$ -Koaleszenzprozess  $(R_t^{(m)})_{t \geq 0}$ .

*Beweis.* Wie im Beweis zu 3.11 vermerken wir auch hier, dass es ausreicht, den Übergang  $n \rightarrow (n-1)$  zu betrachten. Dies ergibt sich leicht aus der Feststellung

$$\rho_{m,n} = \rho_{m,n-1} \circ \rho_{n-1,n}$$

für  $m < n-1$ .

Sei also  $(R_t)_{t \geq 0}$  ein  $n$ -Koaleszenzprozess und  $\rho \stackrel{\text{def}}{=} \rho_{n-1,n} : \mathcal{E}_n \rightarrow \mathcal{E}_{n-1}$  die oben definierte Einschränkungsabbildung. Seien ferner  $\xi \in \mathcal{E}_{n-1}$  und wähle  $\nu \in \mathcal{E}_n$  derart, dass  $\rho\nu = \xi$  gilt.

Darüber hinaus sei an dieser Stelle davon ausgegangen, dass  $(R_t)_{t \geq 0}$  in  $\nu$  startet (vgl. [5]): Bezeichne  $\sigma_\nu \stackrel{\text{def}}{=} \inf\{t \geq 0 : R_t = \nu\}$  die (Erst-)Eintrittszeit in den Zustand  $\nu$ . Dann ist  $\nu$  eine Stoppzeit (vgl. (1.22); da der Wert 0 nur angenommen wird, wenn  $\nu = \Delta_n$  gilt) und vermöge der starken Markov-Eigenschaft, sowie der zeitlichen Homogenität ist  $(R_{\sigma_\nu+t})_{t \geq 0}$  ein Markov-Prozess mit denselben Übergangsraten wie ein  $n$ -Koaleszenzprozess, der jedoch in  $\nu$  startet.

Falls nun ein  $m \in \{1, 2, \dots, n-1\}$  mit  $m \sim_\nu n$  existiert, das heißt, falls die Äquivalenzklasse von  $n$  in  $\nu$  nicht eelementig ist, so gilt bereits  $|\nu| = |\xi|$  und für jedes  $\mu \in \mathcal{E}_n$  mit  $\nu \prec \mu$  gilt  $\rho\nu \prec \rho\mu$ . Darüber hinaus gilt natürlich auch  $\rho\mu \neq \rho\mu'$  für alle  $\mu, \mu' \in \mathcal{E}_n$  mit  $\nu \prec \mu, \nu \prec \mu', \mu \neq \mu'$ . Damit stimmt das Übergangsverhalten von  $(R_t)_{t \geq 0}$  und  $(\rho R_t)_{t \geq 0}$  überein.

Sei also nun die Äquivalenzklasse von  $n$  in  $\nu$  eelementig und setze  $k \stackrel{\text{def}}{=} |\nu|$ . Bezeichne  $\sigma$  die Zeit bis zum ersten Sprung aus  $\nu$  heraus. Dann genügt  $\sigma$  einer Exponentialverteilung mit Parameter  $\binom{k}{2}$ . Bezeichne mit  $\mu = R_\sigma$  den Zustand von  $R_t$  nach dem ersten Sprung. Dann entspricht die Verteilung von  $\mu$  der Gleichverteilung auf der Menge der Äquivalenzrelationen, welche durch Verschmelzung zweier Äquivalenzklassen von  $\nu$  entstehen. Davon sind  $k-1$  dieser Relationen durch Verschmelzungen der Äquivalenzklassen von  $n$  mit einer der übrigen  $k-1$  Äquivalenzklassen entstanden. Bezeichne also mit  $N$  das Ereignis, dass die Äquivalenzklasse von  $n$  in  $\mu$  weiterhin eelementig ist. Offensichtlich gilt dann  $P(N) = \frac{k-2}{k}$  und, bedingt unter  $N$ , entspricht die Verteilung von  $\rho\mu$  der Gleichverteilung auf den  $\binom{k-1}{2}$  möglichen Verschmelzungen zweier Äquivalenzrelationen von  $\rho\nu$ .

Falls also  $N$  nicht eintritt, so bezeichne mit  $\sigma'$  die Zeit bis zum zweiten Sprung aus  $\nu$  heraus. Dies entspricht der Zeit bis zum ersten Sprung aus  $\mu$  heraus und genügt damit einer Exponentialverteilung mit Parameter  $\binom{k-1}{2}$ . Bezeichne mit  $\mu' \stackrel{\text{def}}{=} R_{\sigma+\sigma'}$  den Zustand von  $(R_t)_{t \geq 0}$  nach dem zweiten Sprung. Dann entspricht die Verteilung von  $\rho\mu'$  der Gleichverteilung auf den  $\binom{k-1}{2}$  möglichen Äquivalenzrelationen, die durch Verschmelzung zweier Äquivalenzklassen von  $\rho\nu$  hervorgehen.

$\rho R_t$  verweilt nun also bis zum Zeitpunkt  $\sigma + \mathbb{1}_{\{N^c\}}\sigma'$  im Zustand  $\xi$  und springt dann beim Eintreten von  $N$  in den Zustand  $\mu$  und beim Nichteintreten von  $N$  in den Zustand  $\mu'$ . Darüber hinaus hängt das Sprungziel nicht von den Zeitpunkten der Sprünge ab.

Es ist leicht einzusehen, dass die Voraussetzungen von A.6 gegeben sind. Damit genügt also  $\sigma + \mathbb{1}_{\{N^c\}}\sigma'$  einer Exponentialverteilung mit Parameter  $\binom{k-1}{2}$ .

Insgesamt verweilt also  $(\rho R_t)_{t \geq 0}$  eine  $\binom{|\xi|}{2}$ -verteilte Zeit im Zustand  $\xi$  und springt dann mit gleicher Wahrscheinlichkeit in eine der  $\binom{|\xi|-1}{2}$  Äquivalenzrelationen, welche durch Verschmelzung zweier Äquivalenzklassen von  $\xi$  hervorgehen.  $\square$

Im Kontext des  $n$ -Koaleszenzprozesses als asymptotisches Modell für die Genealogie einer Population, erinnern wir daran, dass die Äquivalenzklassen mit Individuen assoziiert sind. Die spezielle Wahl der Einschränkungsabbildung  $\rho_{m,n}$  bevorzugt bei der Betrachtung von Subpopulationen der Größe  $k$  einer Population der Größe  $n$  gerade die ersten  $k$  Individuen.

Man überlegt sich allerdings, dass die Assoziation von Individuen und Äquivalenzklassen auch in anderer Reihenfolge getroffen werden kann, und dass dies keine Auswirkung auf die Gestalt der Genealogie (unter neutraler Evolution) haben sollte.

Formalisiert wird dies durch den Begriff der Austauschbarkeit (vgl. unter anderem [14] oder [15]), auf den im Folgenden eingegangen wird.

### 3.13 Definition

Für  $n \in \mathbb{N}$  bezeichne

(i)

$$S_n \stackrel{\text{def}}{=} \{\pi : \{1, 2, \dots, n\} \rightarrow \{1, 2, \dots, n\} \mid \pi \text{ bijektiv}\},$$

die *symmetrische Gruppe* von  $\{1, 2, \dots, n\}$ ,

(ii)

$$S_{\mathbb{N}} \stackrel{\text{def}}{=} \{\pi : \mathbb{N} \rightarrow \mathbb{N} \mid \pi \text{ bijektiv}\},$$

die *(unendliche) symmetrische Gruppe* von  $\mathbb{N}$  und

(iii)

$$S_{\mathbb{N}}^{\text{fin}} \stackrel{\text{def}}{=} \{\pi \in S_{\mathbb{N}} \mid |\text{supp}(\pi)| < \infty\},$$

die *(unendliche) symmetrische Gruppe* von  $\mathbb{N}$  mit endlichem Träger, wobei wir mit  $\text{supp}(\pi) \stackrel{\text{def}}{=} \{n \in \mathbb{N} \mid \pi(n) \neq n\}$  den Träger von  $\pi$  bezeichnen.

### 3.14 Definition

Eine (zufällige) Äquivalenzrelation  $\xi \in \mathcal{E}$  heißt *austauschbar*, falls ihre Verteilung invariant unter der Wirkung jeder Permutation  $\pi \in S_{\mathbb{N}}^{\text{fin}}$  mit endlichem Träger ist, wobei die Wirkung von  $\pi$  auf  $\xi$  gemäß

$$\pi\xi = \xi_{\pi} \stackrel{\text{def}}{=} \{(i, j) : i, j \in \mathbb{N}, (\pi(i), \pi(j)) \in \xi\} \quad (3.17)$$

definiert ist.

Für (zufällige) Äquivalenzrelationen  $\xi \in \mathcal{E}_n$  reduziert sich 3.14 offensichtlich auf die Invarianz der Verteilung von  $\xi$  unter der Wirkung der Permutationen  $\pi \in S_n$ .

### 3.15 Bemerkung

Man überlegt sich leicht, dass die in (3.17) definierte Abbildung  $S_{\mathbb{N}}^{\text{fin}} \times \mathcal{E} \rightarrow \mathcal{E}, (\pi, \xi) \rightarrow \xi_{\pi}$  tatsächlich eine Wirkung im Sinne der Gruppentheorie ist.

### 3.16 Proposition

Der  $n$ -Koaleszenzprozess nach Kingman ist austauschbar. Dabei bezeichnen wir einen stochastischen Prozess  $(R_t)_{t \geq 0}$  mit Werten in  $\mathcal{E}_n$  als austauschbar, wenn

$$(R_t)_{t \geq 0} \stackrel{\text{d}}{=} (\pi R_t)_{t \geq 0} \quad (3.18)$$

für alle  $\pi \in S_n$  gilt.

*Beweis.* Der Beweis folgt unmittelbar aus der Tatsache, dass das Verhalten eines  $n$ -Koaleszenzprozesses lediglich von der Anzahl der Äquivalenzklassen abhängt. Diese ist invariant unter  $\pi \in S_n$ . Darüber hinaus ist  $\pi$  nicht nur mit der Anzahl der Äquivalenzklassen verträglich, sondern auch mit der Größe der Äquivalenzklassen.  $\square$

Bevor wir uns nun mit der Frage nach der Existenz eines stochastischen Prozesses befassen, der  $n$ -Koaleszenzprozesse für alle  $n \in \mathbb{N}$  enthält, wollen wir zunächst festhalten, dass der Raum  $\mathcal{E}$  der Äquivalenzrelationen auf  $\mathbb{N}$ , versehen mit einer geeigneten Topologie, ein polnischer Raum ist.

Wir folgen dazu Lemma 2.6 in [5], definieren aber zunächst noch Einschränkungabbildungen  $\rho_n : \mathcal{E} \rightarrow \mathcal{E}_n$ ,  $n \in \mathbb{N}$ , analog zu 3.12, gemäß

$$\rho_n(\xi) \stackrel{\text{def}}{=} \{(i, j) | 1 \leq i, j \leq n : (i, j) \in \xi\} \quad (3.19)$$

für alle  $\xi \in \mathcal{E}$ .

**3.17 Lemma**

Die Abbildung  $d : \mathcal{E} \times \mathcal{E} \rightarrow \mathbb{R}$ , definiert durch

$$d(\xi, \xi') \stackrel{\text{def}}{=} \frac{1}{\sup\{n \in \mathbb{N} : \rho_n \xi = \rho_n \xi'\}}, \quad (3.20)$$

für  $\xi, \xi' \in \mathcal{E}$ , mit der Konvention  $1/\sup \mathbb{N} = 0$ , ist eine Ultrametrik.

*Beweis.* Wir beginnen mit der Feststellung, dass lediglich der Nachweis der starken Dreiecksungleichung nicht offensichtlich ist. Seien also  $\xi, \eta, \nu \in \mathcal{E}$  verschiedene Äquivalenzrelationen. Sei ferner  $d(\xi, \nu) = 1/k$  und  $d(\xi, \eta) = 1/n$ . Für  $n \leq k$  folgt  $d(\eta, \nu) = 1/n \geq 1/k$ . Im Fall  $n > k$  gilt aber bereits  $d(\eta, \nu) = 1/k$ . Denn angenommen  $\eta$  und  $\nu$  würden auch unter  $\rho_{k+1}$  übereinstimmen, so wäre dies auch für  $\xi$  und  $\nu$  der Fall, was einen Widerspruch zur Annahme liefern würde. Insgesamt ergibt sich nun

$$d(\xi, \nu) \leq \max\{d(\xi, \eta), d(\eta, \nu)\}, \quad (3.21)$$

$d$  ist also eine Ultrametrik.  $\square$

**3.18 Proposition**

Der Raum  $(\mathcal{E}, d)$  der Äquivalenzrelationen auf  $\mathbb{N}$ , versehen mit der in (3.20) definierten Metrik  $d$ , ist kompakt.

*Beweis.* Sei  $(\xi_n)_{n \in \mathbb{N}} \subset \mathcal{E}$  eine Folge von Äquivalenzrelationen auf den natürlichen Zahlen.

Wir stellen zunächst fest, dass  $(\rho_1 \xi_n)_n$  eine identische Folge ist. Mithin finden wir eine Teilfolge  $(\xi_{1,n})_n$  derart, dass  $d(\xi_{1,n}, \xi_{1,n'}) \leq 1$  für alle  $n, n'$  gilt. Ferner überlegen wir uns, dass für eine Folge  $(\nu_{k,n})_n \subset \mathcal{E}$  mit  $d(\nu_{k,n}, \nu_{k,n'}) \leq 1/k$  für alle  $n, n'$  die Menge  $\{\rho_{k+1} \nu_{k,n} : n \in \mathbb{N}\}$  höchstens  $(k+1)$ -elementig ist. Dies liefert die Existenz einer Teilfolge  $(\nu_{k+1,n})_n$  derart, dass  $d(\nu_{k+1,n}, \nu_{k+1,n'}) \leq 1/(k+1)$  für alle  $n, n'$ . Zusammen ergeben sich so Teilfolgen  $\xi^{(k)} \stackrel{\text{def}}{=} (\xi_{k,n})_n$  derart, dass  $\xi^{(k+1)}$  eine Teilfolge von  $\xi^{(k)}$  ist, und  $d(\xi_{k,n}, \xi_{k,n'}) \leq 1/k$  für alle  $n, n'$ .

Für die diagonale Folge  $(\nu_n)_n \stackrel{\text{def}}{=} (\xi_{n,n})_n$  ergibt sich damit für alle  $k \in \mathbb{N}$

$$\rho_k \nu_n = \rho_k \nu_{n'} \quad (3.22)$$

für alle  $n, n' \geq k$ , und damit  $d(\nu_n, \nu_{n'}) \leq 1/k$  für alle  $n, n' \geq k$ .

Insbesondere können wir  $(\nu_n)_n$  als Äquivalenzrelation auf den natürlichen Zahlen auffassen, indem wir eine Äquivalenzrelation  $\xi \in \mathcal{E}$  als Element  $(\rho_n \xi)_n \in \bigtimes_{i=1}^{\infty} \mathcal{E}_n$  auffassen.

Das Bild von  $\mathcal{E}$  unter der so beschriebenen Einbettung sind dann gerade die Elemente von  $\bigtimes_{i=1}^{\infty} \mathcal{E}_n$ , die *regulär* im Sinne von (3.22) sind.

Damit besitzt jede Folge in  $(\mathcal{E}, d)$  eine konvergente Teilfolge und  $(\mathcal{E}, d)$  ist demnach ein kompakter metrischer Raum.  $\square$

### 3.19 Bemerkung

Gemäß 3.3 in [10] erzeugt die Metrik  $d'(\xi, \eta) \stackrel{\text{def}}{=} \sup_{n \in \mathbb{N}} 2^{-n} \mathbb{1}_{\{\rho_n \xi \neq \rho_n \eta\}}$  die von den Einschränkungsabbildungen  $\rho_n$  erzeugte Topologie, das heißt die schwächste Topologie, bezüglich der die Einschränkungsabbildungen  $\rho_n$  stetig sind. Ferner ist gemäß Lemma 9 in [10] der Raum  $(\mathcal{E}, d')$  kompakt und total unzusammenhängend und insbesondere polnisch (vgl. auch [4]).

Man überlegt sich leicht, dass  $d$  und  $d'$  vermöge der Beziehung

$$d(\xi, \xi') = 1/k \Leftrightarrow d'(\xi, \xi') = 1/2^k$$

äquivalente Metriken bilden.

### 3.20 Satz

Es existiert ein Wahrscheinlichkeitsraum  $(\Omega, \mathfrak{A}, P)$  und ein eindeutig verteilter stochastischer Prozess  $(R_t)_{t \geq 0}$  mit Werten in  $\mathcal{E}$ , so dass für die Einschränkungsabbildungen  $\rho_n : \mathcal{E} \rightarrow \mathcal{E}_n$ ,  $n \in \mathbb{N}$ , gemäß (3.19), die eingeschränkten Prozesse  $(\rho_n R_t)_{t \geq 0}$  jeweils  $n$ -Koaleszenzprozesse sind.  $(R_t)_{t \geq 0}$  heißt dann *Kingmans Koaleszenzprozess* oder *Koaleszenzprozess nach Kingman*.

*Beweis.* Wir folgen [4] in der Feststellung, dass eine Äquivalenzrelation  $\xi$  auf  $\mathbb{N}$  als eine Funktion  $\delta : \mathbb{N} \rightarrow \mathbb{N}$  verstanden werden kann, indem wir jede natürliche Zahl auf die kleinste zu ihr bezüglich  $\xi$  äquivalente natürliche Zahl abbilden, das heißt

$$\delta(n) \stackrel{\text{def}}{=} \min\{k \in \mathbb{N} : k \sim_{\xi} n\}.$$

Man überlegt sich leicht, dass für jede Äquivalenzrelation genau eine solche Funktion existiert und auch jede solche Funktion eine eindeutige Äquivalenzrelation beschreibt.

Damit lässt sich ein Prozess  $(R_t)_{t \geq 0}$  auf  $\mathcal{E}$  formal als Prozess mit Indexmenge  $\mathbb{N}$  und Zustandsraum  $\mathbb{N}^{[0, \infty)}$  auffassen.

Im Hinblick auf die endlich-dimensionalen Verteilungen dieses Prozesses notieren wir, dass für jede endliche Teilmenge  $I \subset \mathbb{N}$  offensichtlich ein  $k \in \mathbb{N}$  existiert, derart dass  $I \subset \{1, 2, \dots, k\}$ . Sei ferner  $J \subset I$ . Vermöge der Austauschbarkeit von  $n$ -Koaleszenzprozessen dürfen wir ferner annehmen, dass  $I, J$  von der Gestalt  $\{1, 2, \dots, l\}$  mit  $l \in \{|I|, |J|\}$  sind.

Mit dem Satz von Daniell-Kolmogorov (vgl. Satz 54.7 in [2]) folgt damit die Existenz eines eindeutigen Maßes  $Q$  auf den Äquivalenzrelationen von  $\mathbb{N}$  mit den vorgegebenen Randverteilungen und mithin die Existenz eines eindeutig verteilten stochastischen Prozesses  $(R_t)_{t \geq 0}$  auf  $\mathcal{E}$ , derart dass  $(\rho_n R_t)_{t \geq 0}$  der Verteilung eines  $n$ -Koaleszenzprozesses genügt.  $\square$

Für konstruktive Beweise sei an dieser Stelle unter anderem auf Theorem 3 in [14] oder Proposition 2.1 in [4] verwiesen.

### 3.21 Bemerkung

Wie schon im Fall der  $n$ -Koaleszenzprozesse führt auch hier die Eindeutigkeit in Verteilung dazu, dass auch von *dem* Koaleszenzprozess gesprochen wird.

### 3.22 Proposition

Der Koaleszenzprozess nach Kingman ist austauschbar.

*Beweis.* Es sei  $(R_t)_{t \geq 0}$  ein Koaleszenzprozess und  $\pi \in S_{\mathbb{N}}^{\text{fin}}$  eine Permutation der natürlichen Zahlen mit endlichem Träger, dann gibt es ein  $n \in \mathbb{N}$  derart, dass  $\text{supp}(\pi) \subset \{1, 2, \dots, n\}$  gilt. Wir wir in 3.16 bereits gesehen haben, ist  $(\rho_k R_t)_{t \geq 0}$  austauschbar für alle  $k \geq n$ . Damit ist aber auch  $(R_t)_{t \geq 0}$  bereits austauschbar.  $\square$

Der Startzustand des Koaleszenzprozesses nach Kingman ist, wie im endlichen Fall, erneut die Äquivalenzrelation, in der jede Äquivalenzklasse einelementig ist. Damit gilt insbesondere  $|R_0| = \infty$ . Man kann jedoch zeigen, dass der Koaleszenzprozess nach positiver Zeit fast sicher nur endlich viele Äquivalenzklassen hat. Wir notieren (vgl. Theorem 2.1 in [4]):

### 3.23 Proposition

Für einen Koaleszenzprozess  $(R_t)_{t \geq 0}$ , gilt

$$P(|R_t| < \infty, t > 0) = 1,$$

das heißt, ein Koaleszenzprozess besitzt zu jedem Zeitpunkt  $t > 0$  fast sicher nur endlich viele Äquivalenzklassen.

*Beweis.* Es ist ausreichend zu zeigen, dass für jedes  $\epsilon > 0$  ein  $M > 0$  derart existiert, dass  $P(|R_t| > M) \leq \epsilon$ . Dazu betrachten wir die Einschränkungen auf die eingebetteten  $n$ -Koaleszenzprozesse  $(R_t^{(n)})_{t \geq 0} \stackrel{\text{def}}{=} (\rho_n R_t)_{t \geq 0}$  und wählen exponentialverteilte Zufallsvariablen  $\tau_n$  mit Parameter  $\binom{n}{2}$ . Die Wahrscheinlichkeit, dass  $(R_t^{(n)})_{t \geq 0}$  zum Zeitpunkt  $t$  noch mehr als  $M$  Äquivalenzklassen hat, ergibt sich als die Wahrscheinlichkeit, dass die

Summe der ersten  $M$  Verweildauern des assoziierten Todesprozesse  $(D_t^{(n)})_{t \geq 0}$  den Wert  $t$  nicht überschreitet. Vermöge der Markov-Ungleichung (vgl. Satz 17.4 in [2]) für die monotone identische Abbildung, erhalten wir

$$\begin{aligned} \mathbb{P}(|R_t^{(n)}| > M) &= \mathbb{P}\left(\sum_{k=M}^n \tau_k > t\right) \\ &\leq \frac{1}{t} \mathbb{E}\left(\sum_{k=M}^n \tau_k\right) \\ &\leq \frac{1}{t} \sum_{k=M}^{\infty} \frac{2}{k(k-1)} \\ &= \frac{2}{t} \sum_{k=M}^{\infty} \left(\frac{1}{k-1} - \frac{1}{k}\right) = \frac{2}{t(M-1)}. \end{aligned}$$

Daraus ergibt sich

$$\limsup_{n \rightarrow \infty} \mathbb{P}(|R_t^{(n)}| > M) \leq \frac{2}{t(M-1)}$$

und folglich  $\limsup_{n \rightarrow \infty} \mathbb{P}(|R_t^{(n)}| > M) \leq \epsilon$  für alle  $M > \lceil \frac{2}{\epsilon t} \rceil + 1$  und mithin

$$\mathbb{P}(|R_t| > M) \leq \epsilon.$$

Sei nun  $\epsilon_n$  eine monotone Nullfolge. Dies liefert eine monoton wachsende Folge  $(M_n)_n$  mit  $\lim_{n \rightarrow \infty} M_n = \infty$ . Ferner definiert  $A_n \stackrel{\text{def}}{=} \{|R_t| > M_n\}$  eine antitone Mengenfolge mit  $A \stackrel{\text{def}}{=} \lim_{n \rightarrow \infty} A_n = \{|R_t| = \infty\}$ . Vermöge der Stetigkeit von oben (vgl. Satz 2.3 in [2]), gilt

$$\mathbb{P}(|R_t| = \infty) = \mathbb{P}(\lim_{n \rightarrow \infty} A_n) = \lim_{n \rightarrow \infty} \mathbb{P}(A_n) \leq \lim_{n \rightarrow \infty} \epsilon_n = 0,$$

und damit die Behauptung.  $\square$

### 3.4. Genealogische Bäume

Als Prozess auf den Äquivalenzklassen von  $\{1, \dots, n\}$  ist ein  $n$ -Koaleszenzprozess eine relativ abstrakte Realisierung der vergleichsweise einfachen Sprungdynamik. Mit der Zerlegung des Prozesses in seine eingebettete diskrete Markov-Kette und zugehörigen Todesprozess (vgl. 3.6), lässt sich auf natürliche Weise ein  $n$ -Koaleszenzprozess  $(R_t)_{t \geq 0}$  mit einem zufälligen, binären Wurzelbaum assoziieren, in welchem die Blätter mit den verschiedenen Äquivalenzklassen korrespondieren, und die Zweige proportional zu den sukzessiven Sprungzeiten von  $(D_t)_{t \geq 0}$  dargestellt werden (siehe auch [19]), das heißt, wir können Koaleszenzprozesse als baumwertige Prozesse auffassen.

### 3.24 Definition

Ein gerichteter Graph  $G$  ist ein Paar  $(V, E)$ , bestehend aus einer *Knotenmenge*  $V$  und einer *Kantenmenge*  $E \subset V \times V$ . Seien  $v, w \in V$  zwei Knoten. Wir sagen dann, dass eine Kante von  $v$  nach  $w$  geht, falls  $(v, w) \in E$ . Da dies für unsere Fälle ausreichend ist, sei ferner  $G$  *schleifenfrei*, das heißt,  $(v, v) \notin E$  für alle  $v \in V$ .

Wir sagen, dass für zwei Knoten  $v, w \in V$  ein *Pfad* oder *Weg* von  $v$  nach  $w$  existiert, wenn eine Folge  $(x_n)_{1 \leq n \leq k}$  mit  $x_1 = v$  und  $x_k = w$  existiert, so dass

$$(x_i, x_{i+1}) \in E \text{ für alle } i \in \{1, 2, \dots, k-1\}$$

Ferner bezeichnen wir mit

$$\deg_{\text{out}}(v) \stackrel{\text{def}}{=} |\{w \in V : (v, w) \in E\}| \quad (3.23)$$

$$\deg_{\text{in}}(v) \stackrel{\text{def}}{=} |\{w \in V : (w, v) \in E\}| \quad (3.24)$$

den *Ausgangsgrad*, beziehungsweise den *Eingangsgrad* von  $v$ .

### 3.25 Definition

Ein *Wurzelbaum* ist ein gerichteter Graph  $T = (V, E)$  mit einer ausgezeichneten Wurzel  $r \in V$  derart, dass

- (i) für alle  $v \in V \setminus \{r\}$  ein Pfad von  $v$  nach  $r$  existiert, oder
- (ii) für alle  $v \in V \setminus \{r\}$  ein Pfad von  $r$  nach  $v$  existiert.

$T$  heißt ferner *binär*, falls

(i')  $\deg_{\text{in}}(v) \in \{0, 2\}$  und  $\deg_{\text{out}}(v) \in \{0, 1\}$ , im Fall (i),

(ii')  $\deg_{\text{out}}(v) \in \{0, 2\}$  und  $\deg_{\text{in}}(v) \in \{0, 1\}$ , im Fall (ii),

für alle Knoten  $v \in V$  gilt.

### 3.26 Definition

Wir betrachten an dieser Stelle einen schleifenfreien, ungerichteten Graph  $G$  als Paar  $(V, E)$ , bestehend aus der Knotenmenge  $V$  und der Kantenmenge  $E \subset \{\{v, w\} : v \neq w \in V\}$ . Eine Kante ist demnach eine zweielementige Teilmenge der Knotenmenge. Wir bezeichnen mit

$$\deg(v) \stackrel{\text{def}}{=} |\{e \in E : v \in e\}|$$

den Knotengrad von  $v$ .

**3.27 Bemerkung**

Vermöge der Feststellung, dass für einen binären Wurzelbaum mit Wurzel  $r \in V$

$$\deg_{\text{in}}(v) + \deg_{\text{out}}(v) \begin{cases} = 2, & \text{falls } v = r \\ \in \{1, 3\}, & \text{sonst.} \end{cases}$$

gilt, können wir einen binären Wurzelbaum auch als ungerichteten Graphen auffassen.

Ein binärer Wurzelbaum lässt sich demnach auf sehr natürliche Form als Darstellung einer Realisierung eines  $n$ -Koaleszenzprozesses  $(R_t)_{t \geq 0}$  auffassen und konstruieren.

**3.28 Bemerkung**

Beginnend mit  $n$  Knoten, korrespondierend zu den Äquivalenzklassen von  $R_0 = \Delta_n$  und einer leeren Kantenmenge, fügt man für jedes Koaleszenzereignis einen neuen Knoten, sowie neue Kanten zwischen diesem und den Knoten, welche zu den am Verschmelzungereignis beteiligten Äquivalenzklassen assoziiert sind, ein. Offensichtlich liefert diese Konstruktion dann einen binären Wurzelbaum.

**3.29 Definition**

Sei  $G = (V, E)$  ein schleifenfreier, ungerichteter Graph, sowie  $|V| > 1$ . Ein Knoten  $v \in V$  heißt *äußerer* oder *externer Knoten*, falls  $\deg(v) = 1$  gilt und *innerer Knoten* andernfalls.

Entsprechend heißt eine Kante *äußere* oder *externe Kante*, falls einer ihrer Endpunkte ein äußerer Knoten ist, und *innere Kante* andernfalls.

Ist  $G$  ein Baum, so bezeichnen wir Kanten auch als *Zweige* und externe Knoten als *Blätter*.

Die externen Knoten eines zur Realisierung eines  $n$ -Koaleszenzprozesses assoziierten binären Wurzelbaumes sind damit gerade die den einelementigen Äquivalenzklassen zugeordneten Knoten.

**3.30 Definition**

Ein gewichteter Graph  $W$  ist ein Tripel  $(V, E, w)$ , bestehend aus einem Graphen  $G = (V, E)$  und einer Gewichtsfunktion  $w : E \rightarrow \mathbb{R}$ .

Für eine positive Gewichtsfunktion können wir die Gewichte über die Kantenlängen darstellen. Darauf hinaus lässt sich die Konstruktion gemäß 3.28 einfach um die Konstruktion einer Gewichtsfunktion mithilfe der Sprungzeiten des zugrundeliegenden Markov-Sprungprozesses erweitern. Dabei entsteht ein Baum, in welchem alle externen Knoten denselben Abstand zur Wurzel haben.

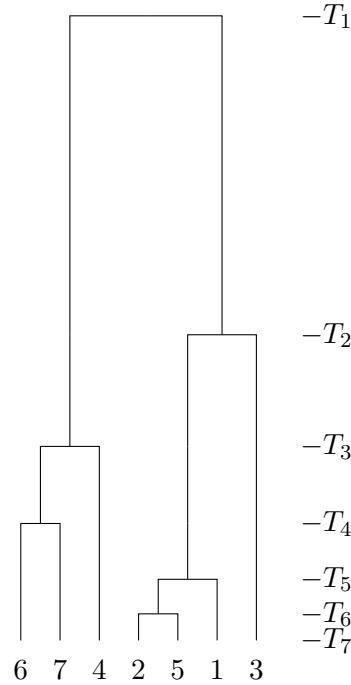


Abbildung 3.1.: Zu einem Koaleszenzprozess assoziierter zufälliger, binärer Wurzelbaum mit externen Knoten  $1, 2, \dots, 7$ . Hierbei bezeichnen  $T_i$  die sukzessiven Sprungzeitpunkte, d.h.  $T_{i+1} - T_i = \tau_i$ .

### 3.31 Definition

Für einen  $n$ -Koaleszenzprozess  $(R_t)_{t \geq 0}$  bezeichnen wir den zufälligen, binären Wurzelbaum, der sich gemäß des oben angegebenen, pfadweisen Konstruktionsverfahrens ergibt, als *Koaleszenzbaum* (zu  $(R_t)_{t \geq 0}$ ).

### 3.32 Bemerkung

In Koaleszenzbäumen nimmt 3.11 die einfache Gestalt an, den unteren Teil des Baumes abzuschneiden.

### 3.33 Proposition

Für die Anzahl der Knoten eines binären Wurzelbaumes  $T = (V, E)$  gilt:

- (i) Es existiert ein  $k \in \mathbb{N}_0$  mit  $|V| = 2k - 1$ .
- (ii) Es existieren in diesem Fall genau  $k$  externe Knoten

Darüber hinaus gibt es dann auch genau  $2k - 2$  Kanten.

*Beweis.* Die Aussagen ergeben sich leicht per Induktion aus der Überlegung, dass jeder Wurzelbaum  $T = (V, E)$  mit Wurzelknoten  $r$  genau zwei Unterwurzelbäume  $T', T''$  enthält. Die Wurzelknoten von  $T'$  und  $T''$  sind gerade die zwei Kindknoten von  $r$ . Für die Knotenzahl von  $T'$  beziehungsweise  $T''$  existieren dann per Induktionsvoraussetzung  $k', k'' \in \mathbb{N}_0$ , so dass wir

$$|V| = 1 + (2k' - 1) + (2k'' - 1) = 2(k' + k'') - 1$$

erhalten. Analog ergibt sich, dass die Anzahl externer Knoten gerade die Summe über die Anzahl externer Knoten der beiden Teilbäume ist. Als unweigerliche Konsequenz aus der Tatsache, dass an einem Verschmelzungsvorgang stets genau 2 Kanten beteiligt sind, wird die Wurzel des Baumes nach  $k - 1$  Verschmelzungsvorgängen erreicht, also gibt es  $2(k - 1)$  Kanten.  $\square$

### 3.34 Definition

Für einen gewichteten, binären Wurzelbaum  $T = (V, E, w : E \rightarrow \mathbb{R}_{>0})$  mit Wurzel  $r$ , bezeichnen wir den Abstand zweier Knoten  $v, w \in V$  als

$$d(v, w) = \inf \left\{ \sum_k w(e_k) : (e_k)_k \subset E \text{ ist ein Pfad von } v \text{ nach } w \right\},$$

wobei  $\inf \emptyset = -\infty$  vereinbart sei und ferner die *Höhe* des Baumes mit

$$h(T) \stackrel{\text{def}}{=} \sup \{d(v, r) : \deg(v) = 1\},$$

falls  $|V| > 1$ .

### 3.35 Definition

Wir bezeichnen einen gewichteten, binären Wurzelbaum  $T = (V, E, w : E \rightarrow \mathbb{R}_{>0})$  mit Wurzel  $r$  und  $|V| > 1$  als *regulär beziehungsweise zulässig*, falls

$$d(v, r) = h(T)$$

für alle externen Knoten  $v$  gilt.

Demnach können wir jeden zulässigen, gewichteten, binären Wurzelbaum als Darstellung eines Pfades eines Koaleszenzprozesses auffassen. Entsprechend können wir ein Konstruktionsverfahren für zufällige, gewichtete binäre Wurzelbäume angeben, so dass ihre Verteilungen gerade denen von  $n$ -Koaleszenzprozessessen entsprechen (vgl. [19] oder [9])

Wir haben im Beweis von 3.33 gesehen, dass sich ein binärer Wurzelbaum als Baum, bestehend aus einem Wurzelknoten und zwei Subwurzelbäumen darstellen lässt. Entsprechend können wir zwei Wurzelbäume zu einem einzelnen Wurzelbaum mit neuer Wurzel wie folgt verschmelzen:

### 3.36 Proposition

Seien  $S = (V_S, E_S, w_S : E_S \rightarrow \mathbb{R}_{>0})$  und  $S' = (V_{S'}, E_{S'}, w_{S'} : E_{S'} \rightarrow \mathbb{R}_{>0})$  gewichtete, binäre Wurzelbäume mit  $V_S \cap V_{S'} = \emptyset$  und Wurzeln  $s, s'$ . Sei ferner  $r \notin V_S \cup V_{S'}$ , sowie  $g \in \mathbb{R}_{>0}$ . Ohne Einschränkung sei darüber hinaus  $h(S) \geq h(S')$  angenommen. Vermöge der Definitionen

$$\begin{aligned} V &\stackrel{\text{def}}{=} \{r\} \cup V_S \cup V_{S'} \\ E &\stackrel{\text{def}}{=} \{s, r\} \cup \{s', r\} \cup E_S \cup E_{S'} \\ w(e) &\stackrel{\text{def}}{=} \begin{cases} w_S(e), & \text{für alle } e \in E_S, \\ w_{S'}(e), & \text{für alle } e \in E_{S'}, \\ g, & \text{für } e = \{s, r\}, \\ g + h(S) - h(S'), & \text{für } e = \{s', r\} \end{cases} \end{aligned}$$

liefert dies einen gewichteten, binären Wurzelbaum  $T = (V, E, w)$  mit Höhe  $h(T) = h(S) + g$ . Dieser ist ferner regulär, falls  $S, S'$  regulär sind.

Damit lässt sich nun folgendes Konstruktionsverfahren angeben:

- (i) Beginne mit einem Wald  $T_0 = (T_1, T_2, \dots, T_n)$  von einelementigen Wurzelbäumen, etwa  $T_i = (i, \emptyset, w_0^{(i)})$ , wobei  $w_0^{(i)}$  die leere Abbildung bezeichne.
- (ii) Gegeben einen Wald  $T_k = (T_1, T_2, \dots, T_{n-k})$  regulärer, gewichteter, binärer Wurzelbäume, generiere (unabhängig) eine exponentialverteilte Zeit  $t_{n-k}$  mit Parameter  $\binom{n-k}{2}$ , und führe dann das obige Vorgehen 3.36 mit  $g = t_{n-k}$  solange sukzessive durch, bis der Wald sich auf einen einzelnen Baum reduziert hat. Dies ist offenkundig nach  $n - 1$  Schritten der Fall.

## 4. Längenverteilung externer Zweige in Koaleszenzbäumen

Wie wir in 3.20 gesehen haben, existiert ein Wahrscheinlichkeitsraum  $(\Omega, \mathfrak{A}, P)$  und ein stochastischer Prozess  $(R_t)_{t \geq 0}$  mit Werten in  $\mathcal{E}$  derart, dass die kanonischen Einschränkungen  $(\rho_n R_t)_{t \geq 0}$  auf den Äquivalenzrelationen der natürlichen Zahlen in die Äquivalenzrelationen auf  $\{1, 2, \dots, n\}$  jeweils  $n$ -Koaleszenzprozesse sind. Ferner haben wir in 3.19 gesehen, dass  $\mathcal{E}$  ein polnischer Raum ist. Dies ermöglicht es uns insbesondere Konvergenzaussagen über Eigenschaften von  $n$ -Koaleszenzprozessen zu treffen. Ebenfalls haben wir gesehen, dass sich jeder  $n$ -Koaleszenzprozess als zufälliger binärer Wurzelbaum auffassen lässt.

Wir folgen Caliebe et al. [7] in der Feststellung, dass sich die Länge eines zufällig gewählten externen Zweiges als zufällige Summe exponentialverteilter Zuwächse auffassen lässt und notieren dazu zunächst eine rekursive Darstellung.

Im Folgenden sei stets ein Koaleszenzprozess  $(R_t)_{t \geq 0}$  auf einem Wahrscheinlichkeitsraum  $(\Omega, \mathfrak{A}, P)$  gegeben. Aussagen zu einem Koaleszenzbaum beziehen sich dann auf den zu  $(\rho_n R_t)_{t \geq 0}$  assoziierten zufälligen Baum.

### 4.1 Bemerkung

Für einen  $n$ -Koaleszenzbaum bezeichne  $Z_n$  die Länge eines externen Zweiges, welcher zufällig aus den  $n$  externen Zweigen des Baumes ausgewählt wurde. Aus der Struktur des Koaleszenzbaumes wird klar, dass der so gewählte Zweig entweder am ersten Koaleszenzereignis beteiligt ist, und in dem Fall gilt  $Z_n = T_n$ , oder, dass er an einem späteren Koaleszenzereignis beteiligt ist, in welchem Fall  $Z_n = T_n + R_n$  gilt, wobei  $R_n$  vermöge 3.11 gemäß  $Z_{n-1}$  verteilt ist, das heißt  $R_n \stackrel{\sim}{=} Z_{n-1}$ .

Daraus ergibt sich folgende Rekursion

$$Z_n \stackrel{\sim}{=} B_n Z_{n-1} + T_n, \quad n \geq 3, \quad (4.1)$$

sowie  $Z_2 \stackrel{\sim}{=} T_2$ . Dabei sind für  $n \in \{3, 4, \dots, n\}$  die  $B_n$  bernoulliverteilt mit Parameter  $1 - 2/n$  und die  $T_n$  exponentialverteilt mit Parameter  $\lambda_n = \binom{n}{2}$ . Des Weiteren sind  $Z_2, B_3, \dots, B_n, T_3, \dots, T_n$  unabhängig.

#### 4.2 Proposition

Für einen zufällig gewählten externen Zweig  $Z_n$ ,  $n \geq 3$  gilt für die Erwartung und die Varianz

$$\mathbb{E}Z_n = \frac{2}{n}, \quad (4.2)$$

$$\text{Var}(Z_n) = \frac{8H_n - 12 + 4/n}{n(n-1)}, \quad (4.3)$$

wobei  $H_n \stackrel{\text{def}}{=} \sum_{j=1}^n 1/j$  die  $n$ -te harmonische Zahl bezeichne.

*Beweis.* Wir setzen zunächst  $X_n \stackrel{\text{def}}{=} n(n-1)Z_n$ . Unter Erinnerung an die rekursive Struktur von  $Z_n$  und die Rechenregeln für Erwartungswerte gemäß (4.1) ergibt sich dann vermöge der Unabhängigkeit der  $Z_2, B_3, \dots, B_n, T_3, \dots, T_n$

$$\begin{aligned} \mathbb{E}X_n &= \mathbb{E}(n(n-1)Z_n) \\ &= n(n-1)\mathbb{E}(B_n Z_{n-1} + T_n) \\ &= n(n-1)\mathbb{P}(B_n = 0)\mathbb{E}(B_n Z_{n-1} + T_n | B_n = 0) \\ &\quad + n(n-1)\mathbb{P}(B_n = 1)\mathbb{E}(B_n Z_{n-1} + T_n | B_n = 1) \\ &= n(n-1)\left(\frac{2}{n}\mathbb{E}T_n + \frac{n-2}{n}\mathbb{E}(Z_{n-1} + T_n)\right) \\ &= n(n-1)\mathbb{E}T_n + \mathbb{E}X_{n-1} \\ &= 2 + \mathbb{E}X_{n-1} \end{aligned} \quad (4.4)$$

Iteratives Einsetzen liefert  $\mathbb{E}X_n = 2(n-1)$  und damit folgt

$$\mathbb{E}Z_n = \frac{\mathbb{E}X_n}{n(n-1)} = \frac{2}{n}.$$

Zur Berechnung der Varianz, sei auf den Hinweis verwiesen, dass es sich häufig als nützlich erweist, eine Funktion der eigentlich zu betrachtenden Zufallsvariablen zu untersuchen. Wie in [12] setzen wir nunmehr  $Y_n \stackrel{\text{def}}{=} n(n-1)Z_n^2$  und erhalten

$$\begin{aligned} \mathbb{E}Y_n &= \mathbb{E}[n(n-1)Z_n^2] \\ &= \mathbb{E}[n(n-1)(B_n Z_{n-1} + T_n)^2] \\ &= n(n-1)\mathbb{E}(B_n Z_{n-1} + T_n)^2 \end{aligned}$$

Bedingen unter  $B_n$  liefert dann

$$\begin{aligned}
 \mathbb{E}Y_n &= n(n-1) \mathbb{P}(B_n = 1) \mathbb{E}((B_n Z_{n-1} + T_n)^2 | B_n = 1) \\
 &\quad + n(n-1) \mathbb{P}(B_n = 0) \mathbb{E}((B_n Z_{n-1} + T_n)^2 | B_n = 0) \\
 &= n(n-1) (\mathbb{P}(B_n = 1) \mathbb{E}(T_n + Z_{n-1})^2 + \mathbb{P}(B_n = 0) \mathbb{E}T_n^2) \\
 &= n(n-1) \left( \frac{n-2}{n} \mathbb{E}(T_n + Z_{n-1})^2 + \frac{2}{n} \mathbb{E}T_n^2 \right) \\
 &= (n-1)(n-2) \mathbb{E}(T_n^2 + 2T_n Z_{n-1} + Z_{n-1}^2) + 2(n-1) \mathbb{E}T_n^2 \\
 &= n(n-1) \mathbb{E}T_n^2 + 2(n-1)(n-2) \mathbb{E}T_n Z_{n-1} + \mathbb{E}Y_{n-1}.
 \end{aligned} \tag{4.5}$$

Nun gilt aber für die  $\text{Exp}(\lambda_n)$ -verteilte Zufallsvariable  $T_n$

$$\mathbb{E}T_n = (\lambda_n)^{-1} = \frac{2}{n(n-1)}, \tag{4.6}$$

$$\mathbb{E}T_n^2 = 2(\lambda_n^2)^{-1} = \frac{8}{n^2(n-1)^2}. \tag{4.7}$$

Ebenso ist  $Z_{n-1}$  als Verknüpfung von  $Z_2, B_3, \dots, B_{n-1}, T_3, \dots, T_{n-1}$  unabhängig von  $T_n$  und es gilt mit Verweis auf (4.2)

$$\mathbb{E}T_n Z_{n-1} = \mathbb{E}T_n \mathbb{E}Z_{n-1} = \frac{2}{n(n-1)} \cdot \frac{2}{n-1} = \frac{4}{n(n-1)^2}.$$

Damit ergibt sich für die Erwartung von  $Y_n$  vermöge (4.5)

$$\begin{aligned}
 \mathbb{E}Y_n &= \frac{8}{n(n-1)} + \frac{8(n-2)}{n(n-1)} + \mathbb{E}Y_{n-1} \\
 &= \frac{8(n-1)}{n(n-1)} + \mathbb{E}Y_{n-1} \\
 &= \frac{8}{n} + \mathbb{E}Y_{n-1}.
 \end{aligned} \tag{4.8}$$

Iteratives Einsetzen liefert dann

$$\mathbb{E}Y_n = \frac{8}{n} + \frac{8}{n-1} + \dots + \frac{8}{2} = 8(H_n - 1), \tag{4.9}$$

wobei für den letzten Summanden die Beziehung  $\mathbb{E}Y_2 = 2 \mathbb{E}Z_2^2 = 4$  verwendet wurde.

Unter Berücksichtigung der Linearität des Erwartungswertes erhalten wir daher

$$\mathbb{E}Z_n^2 = \frac{\mathbb{E}Y_n}{n(n-1)} = \frac{8(H_n - 1)}{n(n-1)},$$

und damit weiter für die Varianz von  $Z_n$

$$\text{Var}(Z_n) = \text{EZ}_n^2 - (\text{EZ}_n)^2 = \frac{8(H_n - 1)}{n(n-1)} - \frac{4}{n^2} = \frac{8H_n - 12 + 4/n}{n(n-1)}.$$

□

Wir folgen nunmehr Caliebe et al. [7] in der Feststellung, dass die standardisierte Länge eines zufällig gewählten externen Zweiges  $Z_n$  eines Koaleszenzbaumes keiner nicht-trivialen Verteilung genügt, genauer gilt:

#### 4.3 Proposition

Bezeichne  $Z_n$  die Länge eines zufällig gewählten externen Zweiges eines Koaleszenzbaumes, dann gilt

$$\frac{Z_n - \text{EZ}_n}{\sqrt{\text{Var}(Z_n)}} \xrightarrow{L_1} 0. \quad (4.10)$$

Genauer gilt sogar

$$\left\| \frac{Z_n - \text{EZ}_n}{\sqrt{\text{Var}(Z_n)}} \right\|_1 \in \mathcal{O}\left(\frac{1}{\sqrt{\ln n}}\right). \quad (4.11)$$

*Beweis.* Mit der trivialen Feststellung  $Z_n \geq 0$ , liefert eine Anwendung der Dreiecksungleichung für die  $L_1$ -Norm unter Berücksichtigung von  $\|Z_n\|_1 = \text{EZ}_n$

$$\left\| \frac{Z_n - \text{EZ}_n}{\sqrt{\text{Var}(Z_n)}} \right\|_1 \leq \frac{\|Z_n\|_1}{\sqrt{\text{Var}(Z_n)}} + \frac{\text{EZ}_n}{\sqrt{\text{Var}(Z_n)}} = \frac{2\text{EZ}_n}{\sqrt{\text{Var}(Z_n)}}.$$

Einsetzen von Erwartungswert und Varianz gemäß 4.2 liefert ferner

$$\begin{aligned} \limsup_{n \rightarrow \infty} \frac{2\text{EZ}_n}{\sqrt{\text{Var}(Z_n)}} \sqrt{\ln n} &= \limsup_{n \rightarrow \infty} 4 \left( \frac{n^2(8H_n - 12 + 4/n)}{n(n-1)\ln n} \right)^{-\frac{1}{2}} \\ &\leq \limsup_{n \rightarrow \infty} 4 \left( \frac{n^2(8H_n - 12 + 4/n)}{n^2 \ln n} \right)^{-\frac{1}{2}}. \end{aligned}$$

Aus der bekannten Tatsache  $\lim_{n \rightarrow \infty} (H_n - \ln n) = \gamma$ , wobei  $\gamma$  die Euler-Mascheroni-Konstante bezeichne, erhält man  $\lim_{n \rightarrow \infty} H_n / \ln n = 1$  und mithin

$$\limsup_{n \rightarrow \infty} \frac{2\text{EZ}_n}{\sqrt{\text{Var}(Z_n)}} \sqrt{\ln n} \leq \sqrt{2} < \infty,$$

und somit die zweite Behauptung. □

Insbesondere konvergiert damit die standardisierte Länge eines externen Zweiges in Verteilung gegen 0. Wir folgen weiter [7] in dem Bemühen, eine alternative Normalisierung zu finden.

## 4.1. Eine alternative Darstellung von $Z_n$

Sei  $n \geq 3$ , und  $B_n$  wie in (4.1). Setze weiterhin  $B_2 \equiv 0$ . Definiere nun

$$\tau_n \stackrel{\text{def}}{=} \min\{i \in \{0, \dots, n-2\} : B_{n-i} = 0\}. \quad (4.12)$$

Dann können wir die Verteilung von  $\tau_n$  unmittelbar berechnen und erhalten:

### 4.4 Proposition

Für die in (4.12) definierte Zufallsvariable  $\tau_n$  gilt

$$P(\tau_n = k) = 2 \frac{n-k-1}{n(n-1)} = \frac{2}{n} - \frac{2k}{n(n-1)} \quad (4.13)$$

für  $0 \leq k \leq n-2$ .

*Beweis.* Aus der Unabhängigkeit der  $B_i$  folgt unmittelbar

$$\begin{aligned} P(\tau_n = k) &= P(B_n = B_{n-1} = \dots = B_{n-k+1} = 1, B_{n-k} = 0) \\ &= \left( \prod_{i=0}^{k-1} P(B_{n-i} = 1) \right) \cdot P(B_{n-k} = 0) \\ &= \left( \prod_{i=0}^{k-1} \frac{n-i-2}{n-i} \right) \frac{2}{n-k} = 2 \frac{n-k-1}{n(n-1)}. \end{aligned}$$

□

Im Hinblick auf (4.1) ermöglicht uns dies nun die Darstellung von  $Z_n$  als zufällige Summe der  $T_k$ . Genauer erhalten wir

$$Z_n \underset{k=0}{\overset{\tau_n}{\sum}} T_{n-k}. \quad (4.14)$$

### 4.5 Proposition

Für das gemäß (4.12) definierte  $\tau_n$  gilt

$$\frac{\tau_n}{n} \xrightarrow{d} W, \quad (4.15)$$

wobei  $W$  eine Zufallsvariable auf  $[0, 1]$  mit Verteilungsfunktion

$$P(W \leq x) = x(2-x), \quad x \in [0, 1] \quad (4.16)$$

ist. Für die zu  $W$  gehörende Dichte gilt

$$f_W(x) = 2(1-x), \quad x \in [0, 1]. \quad (4.17)$$

*Beweis.* Es bezeichne  $\lfloor x \rfloor$  die untere Gaußklammer von  $x$ , das heißt  $\lfloor x \rfloor = \max\{n \in \mathbb{Z} \mid n \leq x\}$ . Für  $x \in [0, 1)$  folgt mittels (4.12) und der einfachen Überlegung  $\lfloor nx \rfloor \leq n - 1$  für  $x \in [0, 1)$ , sowie der Tatsache, dass die rechte Seite in (4.13) auch mit  $k = n - 1$  verträglich ist,

$$\begin{aligned} P(\tau_n \leq nx) &= \sum_{k=0}^{\lfloor nx \rfloor} P(\tau_n = k) \\ &= \sum_{k=0}^{\lfloor nx \rfloor} \left( \frac{2}{n} - \frac{2k}{n(n-1)} \right) \\ &= \frac{2(\lfloor nx \rfloor + 1)}{n} - \frac{\lfloor nx \rfloor(\lfloor nx \rfloor + 1)}{n(n-1)} \rightarrow 2x - x^2 = x(2-x), \end{aligned}$$

für  $n \rightarrow \infty$ . Für  $x = 1$  ergibt sich  $P(\tau_n \leq n) = 1 = 2 - 1^2$ . Damit folgt die gewünschte Verteilungskonvergenz gegen eine Zufallsvariable  $W$  auf  $[0, 1]$  mit der in (4.16) gewünschten Verteilungsfunktion.

Die Behauptung für die zu  $W$  gehörende Dichte erschließt sich leicht durch Ableitung der Verteilungsfunktion von  $W$

$$\frac{d}{dx} x(2-x) = x(1-x).$$

□

#### 4.6 Proposition

Für den Erwartungswert und die Varianz von  $\tau_n$  beziehungsweise  $W$  gelten

$$E\tau_n = \frac{n-2}{3}, \quad E\left(\frac{\tau_n}{n}\right) \rightarrow EW = \frac{1}{3}, \quad (4.18)$$

$$\text{Var}(\tau_n) = \frac{n^2 - n - 2}{18}, \quad \text{Var}\left(\frac{\tau_n}{n}\right) \rightarrow \text{Var}(W) = \frac{1}{18}. \quad (4.19)$$

*Beweis.* Gemäß der Definition des Erwartungswertes und unter Verwendung von (4.13)

und A.4, gilt

$$\begin{aligned}
 \mathbb{E}(\tau_n) &= \sum_{k=0}^{n-2} k \mathbb{P}(\tau_n = k) \\
 &= \sum_{k=0}^{n-2} 2k \frac{n-k-1}{n(n-1)} \\
 &= \frac{2(n-1)}{n(n-1)} \sum_{k=0}^{n-2} k - \frac{2}{n(n-1)} \sum_{k=0}^{n-2} k^2 \\
 &= \frac{2}{n} \frac{(n-2)(n-1)}{2} - \frac{2}{n(n-1)} \frac{(n-2)(n-1)(2(n-2)+1)}{6} \\
 &= \frac{n-2}{3}
 \end{aligned}$$

Der Erwartungswert  $EW$  von  $W$  berechnet sich gemäß (4.17) zu

$$\begin{aligned}
 EW &= \int_0^1 2x(1-x) dx \\
 &= 2 \left( \frac{1}{2}x^2 \Big|_0^1 - 2 \left( \frac{1}{3}x^3 \Big|_0^1 \right) \right) = \frac{1}{3}.
 \end{aligned}$$

Es reicht nun vermöge der Linearität des Erwartungswertes der Vermerk

$$\mathbb{E} \left( \frac{\tau_n}{n} \right) = \frac{\mathbb{E} \tau_n}{n} = \frac{1}{3} - \frac{2}{3n} \rightarrow \frac{1}{3}$$

für  $n \rightarrow \infty$ .

Für die Varianz von  $\tau_n$  betrachten wir zunächst  $\mathbb{E}(\tau_n^2)$ . Mit Verweis auf (A.5) für die Summe von dritten Potenzen folgt

$$\begin{aligned}
 \mathbb{E}(\tau_n^2) &= \sum_{k=0}^{n-2} k^2 \mathbb{P}(\tau_n = k) \\
 &= \sum_{k=0}^{n-2} 2k^2 \frac{n-k-1}{n(n-1)} \\
 &= \frac{2}{n} \sum_{k=0}^{n-2} k^2 - \frac{2}{n(n-1)} \sum_{k=0}^{n-2} k^3 \\
 &= \frac{2}{n} \frac{(n-2)(n-1)(2(n-2)+1)}{6} - \frac{2}{n(n-1)} \frac{(n-2)^2(n-1)^2}{4} \\
 &= \frac{(n-1)(n-2)}{6} = \frac{n^2 - 3n + 2}{6}
 \end{aligned} \tag{4.20}$$

Für  $\text{Var}(\tau_n)$  gilt somit

$$\begin{aligned}\text{Var}(\tau_n) &= \mathbb{E}(\tau_n^2) - (\mathbb{E}\tau_n)^2 \\ &= \frac{(n-1)(n-2)}{6} - \frac{(n-2)^2}{9} \\ &= \frac{(n-2)(n+1)}{18} = \frac{n^2 - n - 2}{18}.\end{aligned}$$

Die Varianz von  $W$  berechnet sich ähnlich der obigen Berechnung des Erwartungswertes von  $W$  zu

$$\begin{aligned}\text{Var}(W) &= \mathbb{E}W^2 - (\mathbb{E}W)^2 \\ &= \int_0^1 2x^2(1-x) \, dx \\ &= 2 \left( \frac{1}{3}x^3 - \frac{1}{4}x^4 \right) \Big|_0^1 - \frac{1}{9} = \frac{1}{18},\end{aligned}$$

und auch in diesem Fall reicht der Vermerk von

$$\text{Var}\left(\frac{\tau_n}{n}\right) = \frac{\text{Var}(\tau_n)}{n^2} = \frac{1}{18} \left(1 - \frac{1}{n} - \frac{2}{n^2}\right) \rightarrow \frac{1}{18}$$

für  $n \rightarrow \infty$ . □

#### 4.7 Bemerkung

In [7] finden wir anstelle von (4.19) mit Verweis auf [6] die Behauptung, dass für die Varianz von  $\tau_n$

$$\text{Var}(\tau_n) = \frac{n^2 + 31n - 2}{18}$$

gelte. Dabei betrachteten Blum und François eine Zufallsvariable  $K$ , das *Koaleszenzlevel* von Individuum 1, mit  $K = n - \tau_n$ . Insbesondere bedeutet  $K = k$  also, dass das Individuum 1 beim Übergang von  $k \rightarrow (k-1)$  Äquivalenzklassen zum ersten Mal an einer Verschmelzung beteiligt ist. Bezugnehmend auf (4.13), (4.18) und (4.19) notieren wir

$$\mathbb{P}(K = k) = \mathbb{P}(\tau_n = n - k) = \frac{2}{n} \frac{k-1}{n-1}$$

für  $k \in \{2, 3, \dots, n\}$  und  $\mathbb{E}K = n - \mathbb{E}\tau_n = 2/3(n+1)$  in Übereinstimmung mit [6], aber

$$\text{Var}(K) = \text{Var}(\tau_n) = \frac{1}{18}(n^2 + n - 2)$$

als mögliche Korrektur.

#### 4.8 Proposition

Für die Verteilungsfunktionen  $F_n(x) \stackrel{\text{def}}{=} P(\tau_n/n \leq x)$  und  $F(x) \stackrel{\text{def}}{=} P(W \leq x)$ ,  $x \in [0, 1]$ , von  $\tau_n/n$  beziehungseise  $W$  gilt

$$\|F_n - F\|_\infty = |F_n(0) - F(0)| = F_n(0) = \frac{2}{n}. \quad (4.21)$$

*Beweis.* Wir beginnen mit der einfachen Überlegung, dass die einzigen Punkte, für die die Supremumsnorm angenommen werden kann, vermöge der strengen Monotonie von  $F$  gerade die Unstetigkeitsstellen von  $F_n$  sind. Daher betrachten wir

$$\begin{aligned} P\left(\frac{\tau_n}{n} \leq \frac{i}{n}\right) &= \sum_{k=0}^i \left(\frac{2}{n} - \frac{2k}{n(n-1)}\right) \\ &= \frac{2(i+1)}{n} - \frac{i(i+1)}{n(n+1)} \end{aligned} \quad (4.22)$$

für  $i \in \{0, 1, \dots, n-2\}$  und erhalten weiterhin

$$P\left(\frac{\tau_n}{n} \leq \frac{i}{n}\right) - P\left(W \leq \frac{i}{n}\right) = \frac{2}{n} - \frac{i(n-i)}{n^2(n+1)}, \quad (4.23)$$

womit die Behauptung bewiesen ist.  $\square$

Damit erhalten wir die gleichmäßige Konvergenz von  $F_n(x) \rightarrow F(x)$ , welche schon durch die Stetigkeit von  $F(x)$  gegeben ist, und darüber hinaus auch einen Hinweis auf die Geschwindigkeit der Konvergenz der Verteilungsfunktionen. Insbesondere gilt  $\|F_n - F\|_\infty \in \mathcal{O}(1/n)$ .

Wir folgen weiter Caliebe et al. [7] in ihrem Beweis zur asymptotischen Verhalten von  $Z_n$  und notieren dazu analog zunächst das folgende Lemma:

#### 4.9 Lemma

Für festes  $t > 0$  und  $n/\ln n \leq j \leq n - n/\ln n$  gilt für  $n \rightarrow \infty$

$$\sum_{l=n-1}^n \ln\left(1 + \frac{2tn}{l(l-1)}\right) = \frac{2tj}{n-j} + \mathcal{O}\left(\frac{\ln^3 n}{n}\right), \quad (4.24)$$

wobei der Fehler unabhängig von  $j$  gewählt werden kann, aber von  $t$  abhängt.

*Beweis.* Definiere Restglieder  $R_n$  gemäß

$$\sum_{l=n-j}^n \ln\left(1 + \frac{2tn}{l(l-1)}\right) = \sum_{l=n-j}^n \frac{2tn}{l(l-1)} + R_n,$$

das heißt  $R_n$  ist von der Gestalt

$$R_n = \sum_{l=n-j}^n \ln \left( 1 + \frac{2tn}{l(l-1)} \right) - \frac{2tn}{l(l-1)}.$$

Unter Verwendung von A.2 (jeder Summand ist von der Gestalt  $\ln(1+x)$  für ein  $x > 0$ ) ergibt sich

$$\begin{aligned} |R_n| &\leq \frac{1}{2} \sum_{l=n-j}^n \left( \frac{2tn}{l(l-1)} \right)^2 = 2t^2 n^2 \sum_{l=n-j}^n \frac{1}{l(l-1)} \\ &\leq 2t^2 n^2 \sum_{l=n-j}^n \frac{1}{(l-1)^2} \leq 2t^2 n^2 \sum_{l=n-j}^n \frac{1}{(l-1)^4} \\ &\leq 2t^2 n^2 \sum_{l=n-j}^{\infty} \frac{1}{(l-1)^4} \leq 2t^2 n^2 \int_{n-j-1}^{\infty} \frac{1}{(x-1)^4} dx \end{aligned} \quad (4.25)$$

$$\begin{aligned} &= \frac{2t^2 n^2}{3(n-j-2)^3} \leq \frac{2}{3} \frac{t^2 n^2}{(n/\ln n - 2)^3} \\ &\leq \frac{t^2 n^2}{n^3/\ln^3 n} = \frac{t^2 \ln^3 n}{n}, \end{aligned} \quad (4.26)$$

wobei in (4.25) verwendet wurde, dass  $x \rightarrow 1/(x-1)^4$  monoton fallend für  $x > 1$ , sowie  $n/\ln n \geq 2$  für  $n \geq 2$  ist. Die Ungleichung in (4.26) beruht auf einer Abschätzung von  $j$  nach oben, und der letzte Schritt verwendet erneut die Beziehung  $n/\ln n \geq 2$  für  $n \geq 2$ . Mittels dieser Abschätzung ergibt sich dann

$$\limsup_{n \rightarrow \infty} \left| R_n \frac{n}{\ln^3 n} \right| \leq \limsup_{n \rightarrow \infty} \left| \frac{t^2 \ln^3 n}{n} \frac{n}{\ln^3 n} \right| = t^2 < \infty$$

Damit reicht nun zu zeigen, dass

$$\left| \frac{j}{n-j} - \sum_{l=n-j}^n \frac{n}{l(l-1)} \right| \in \mathcal{O} \left( \frac{\ln^3 n}{n} \right)$$

gilt, denn dann folgt

$$\begin{aligned}
 \sum_{l=n-j}^n \ln \left( 1 + \frac{2tn}{l(l-1)} \right) &= \sum_{l=n-j}^n \frac{2tn}{l(l-1)} + R_n \\
 &= 2t \left( \underbrace{\frac{j}{n-j} - \frac{j}{n-j} + \sum_{l=n-j}^n \frac{n}{l(l-1)}}_{\in \mathcal{O}\left(\frac{\ln^3 n}{n}\right)} \right) + \underbrace{R_n}_{\in \mathcal{O}\left(\frac{\ln^3 n}{n}\right)} \\
 &= \frac{2tj}{n-j} + \mathcal{O}\left(\frac{\ln^3 n}{n}\right)
 \end{aligned}$$

und damit die Behauptung. Deshalb betrachten wir nunmehr

$$\begin{aligned}
 \sum_{l=n-j}^n \frac{n}{l(l-1)} &= n \sum_{l=n-j}^n \left( \frac{1}{l-1} - \frac{1}{l} \right) \\
 &= n \left( \frac{1}{n-j-1} - \frac{1}{n} \right) \\
 &= \frac{j+1}{n-j-1}.
 \end{aligned}$$

Insbesondere ist  $j/(n-j) \leq (j+1)/(n-j)$ , weshalb nun

$$\begin{aligned}
 \left| \frac{j}{n-j} - \sum_{l=n-j}^n \frac{n}{l(l-1)} \right| &= \frac{j+1}{n-j-1} - \frac{j}{n-j} \\
 &= \frac{n}{(n-j)(n-j-1)} \\
 &\leq \frac{n}{(n-n+\frac{n}{\ln n})(n-n+\frac{n}{\ln n}-1)} \\
 &= n \left( \frac{n^2}{\ln^2 n} - \frac{n}{\ln n} \right)^{-1}
 \end{aligned} \tag{4.27}$$

folgt. Damit gilt für

$$\begin{aligned}
 \limsup_{n \rightarrow \infty} \left| \frac{j}{n-j} - \sum_{l=n-j}^n \frac{n}{l(l-1)} \right| \frac{n}{\ln^3 n} &\leq \limsup_{n \rightarrow \infty} \left| \frac{n^2}{\ln^3 n} \left( \frac{n^2}{\ln^2 n} - \frac{n}{\ln n} \right)^{-1} \right| \\
 &= \lim_{n \rightarrow \infty} \left| (\ln n - \ln^2 n)^{-1} \right| = 0 < \infty.
 \end{aligned}$$

Insbesondere kann der Fehler, bestehend aus  $R_n$  und der linken Seite in (4.27) unabhängig von  $j$  abgeschätzt werden, hängt aber von  $t$  ab.  $\square$

Wir können nun Caliebe et al. in ihrem Resultat über die Verteilungskonvergenz externer Zweige von Koaleszenzbäumen mithilfe ihrer Laplace-Transformierten folgen und notieren:

#### 4.10 Satz

Gegeben externe Zweige in Koaleszenzbäumen mit Längen  $Z_n$ , konvergiert  $nZ_n$  für  $n \rightarrow \infty$  in Verteilung gegen  $Z \stackrel{\text{def}}{=} 2W/(1 - W)$ , wobei  $W$  durch (4.15) gegeben ist. Damit ist die zu  $Z$  gehörende Dichtefunktion von der Form  $x \rightarrow 8/(2 + x)^3, x \geq 0$ .

*Beweis.* Wir bezeichnen mit  $\varphi_n$  die Laplace-Transformierte von  $nZ_n$ , das heißt,  $\varphi_n(t) = \mathbb{E} \exp(-tnZ_n), t > 0$ . Mit der im folgenden gezeigten punktweisen Konvergenz von  $\varphi_n$  gegen die Laplace-Transformierte  $\varphi$  von  $Z$ , folgt die Verteilungskonvergenz von  $nZ_n$  gegen  $Z$  (vgl. Satz 42.4 in [2]).

Seien dazu  $I_n \stackrel{\text{def}}{=} [n/\ln n, n - n/\ln n]$  und  $A_n \stackrel{\text{def}}{=} \{\tau_n \in I_n\}$  mit  $\tau_n$  gemäß (4.12)

In einem ersten Schritt vermerken wir  $\mathbb{P}(A_n^c) \in \mathcal{O}(1/\ln n)$ , denn

$$\begin{aligned} \mathbb{P}(A_n^c) &= \mathbb{P}(\tau_n \notin I_n) = \mathbb{P}\left(\frac{\tau_n}{n} \notin \left[\frac{1}{\ln n}, 1 - \frac{1}{\ln n}\right]\right) \\ &= 1 - \mathbb{P}\left(\frac{\tau_n}{n} \leq 1 - \frac{1}{\ln n}\right) + \mathbb{P}\left(\frac{\tau_n}{n} \leq \frac{1}{\ln n}\right). \end{aligned}$$

Vermöge 4.8 erhalten wir für alle  $x \in [0, 1]$

$$\mathbb{P}(W \leq x) - \frac{2}{n} \leq \mathbb{P}\left(\frac{\tau_n}{n} \leq x\right) \leq \mathbb{P}(W \leq x) + \frac{2}{n}, \quad (4.28)$$

und damit bereits

$$\begin{aligned} \mathbb{P}(A_n^c) &\leq 1 - \mathbb{P}\left(W \leq 1 - \frac{1}{\ln n}\right) + \mathbb{P}\left(W \leq \frac{1}{\ln n}\right) + \frac{4}{n} \\ &= \mathbb{P}\left(W \notin \left[\frac{1}{\ln n}, 1 - \frac{1}{\ln n}\right]\right) + \frac{4}{n} \\ &= \frac{2}{\ln n} + \frac{4}{n}. \end{aligned} \quad (4.29)$$

Also gilt  $\limsup_{n \rightarrow \infty} |\mathbb{P}(A_n^c) \cdot \ln n| \leq \limsup_{n \rightarrow \infty} |2 + 4 \ln n/n| = 2 < \infty$ , und mithin  $\mathbb{P}(A_n^c) \in \mathcal{O}(1/\ln n)$ .

Für die Laplace-Transformierte  $\varphi_n(t)$  von  $Z_n$  bedeutet dies

$$\begin{aligned}\varphi_n(t) &= \mathbb{E} \exp(-tnZ_n) = \mathbb{E} \exp\left(-tn \sum_{k=0}^{\tau_n} T_{n-k}\right) \\ &= \int_{A_n \cup A_n^c} \exp\left(-tn \sum_{k=0}^{\tau_n} T_{n-k}\right) \cdot\end{aligned}$$

Es reicht ferner, das Integral über  $A_n$  zu betrachten, da wir vermöge der Beschränkung des Integranden nach oben durch 1 nunmehr

$$\int_{A_n^c} \exp(-tnZ_n) \leq \int_{A_n^c} 1 = \mathbb{P}(A_n^c) \in \mathcal{O}\left(\frac{1}{\ln n}\right)$$

erhalten. Für die Laplace-Transformierte einer  $\text{Exp}(\lambda)$ -verteilten Zufallsvariablen  $X$ ,  $\lambda > 0$  verweisen wir auf Seite 282 in [2] und notieren,

$$\varphi_X(t) = \mathbb{E} \exp(-tX) = \frac{\lambda}{t + \lambda}, \quad t > 0.$$

Damit gilt vermöge der Unabhängigkeit der  $T_i$

$$\begin{aligned}\int_{A_n} \exp\left(-tn \sum_{k=0}^{\tau_n} T_{n-k}\right) &= \sum_{j \in I_n \cap \mathbb{N}} \mathbb{P}(\tau_n = j) \prod_{k=0}^j \mathbb{E} \exp(-tnT_{n-k}) \\ &= \sum_{j \in I_n \cap \mathbb{N}} \mathbb{P}(\tau_n = j) \prod_{k=0}^j \frac{\lambda_{n-k}}{\lambda_{n-k} + tn} \\ &= \sum_{j \in I_n \cap \mathbb{N}} \mathbb{P}(\tau_n = j) \exp\left(-\sum_{k=0}^j \ln\left(1 + \frac{tn}{\lambda_{n-k}}\right)\right) \\ &= \sum_{j \in I_n \cap \mathbb{N}} \mathbb{P}(\tau_n = j) \exp\left(-\sum_{l=n-j}^n \ln\left(1 + \frac{tn}{\lambda_l}\right)\right),\end{aligned}$$

wobei im vorletzten Schritt die Beziehungen  $xy = e^{\ln x}e^{\ln y} = \exp(\ln x + \ln y)$ , sowie  $\ln(x) = -\ln(1/x)$  verwendet wurden, sowie im letzten Schritt die Summe umsortiert wurde. In Erinnerung an  $\lambda_l = \binom{l}{2} = \frac{l(l-1)}{2}$  erfüllt der (negative) Exponent gerade die Voraussetzungen von 4.9. Dies liefert

$$\begin{aligned}\int_{A_n} \exp\left(-tn \sum_{k=0}^{\tau_n} T_{n-k}\right) &= \sum_{j \in I_n \cap \mathbb{N}} \mathbb{P}(\tau_n = j) \exp\left(-\frac{2tj}{n-j} + \mathcal{O}\left(\frac{\ln^3 n}{n}\right)\right) \\ &= \exp\left(\mathcal{O}\left(\frac{\ln^3 n}{n}\right)\right) \int_{A_n} \exp\left(-t \frac{2\tau_n/n}{1 - \tau_n/n}\right),\end{aligned}$$

wobei im letzten Schritt verwendet wurde, dass der Fehler unabhängig von  $j$  abgeschätzt werden kann.

Es gilt nun vermöge A.1 die Konvergenz von  $\exp\left(\mathcal{O}\left(\frac{\ln^3 n}{n}\right)\right) \rightarrow 1$ , für  $n \rightarrow \infty$ . Unter Verwendung von (4.15) und der asymptotischen Vernachlässigbarkeit von  $P(A_n^c)$  ergibt sich insgesamt die Konvergenz der Laplace-Transformierten von  $Z_n$  gegen die Laplace-Transformierte von  $Z$ .

Zur Bestimmung der Dichte von  $Z$  berechnen wir im Weiteren zunächst die Verteilungsfunktion von  $Z$  mithilfe der Verteilung von  $W$  gemäß

$$\begin{aligned} P(Z \leq x) &= P\left(\frac{2W}{1-W} \leq x\right) = P\left(W \leq \frac{x}{2+x}\right) \\ &= \frac{2x}{2+x} - \left(\frac{x}{2+x}\right)^2. \end{aligned} \quad (4.30)$$

Anschließendes Ableiten liefert dann die Dichte von  $Z$

$$\frac{d}{dx} \left[ \frac{2x}{2+x} - \left(\frac{x}{2+x}\right)^2 \right] = \frac{4}{(2+x)^2} - \frac{2x}{2+x} \frac{2}{(2+x)^2} = \frac{8}{(2+x)^3},$$

und damit die Behauptung.  $\square$

Im Hinblick auf Anwendungsbeispiele, notieren wir gemäß [7], dass die Konvergenz von  $nZ_n$  auch unter geringeren Anforderungen an die Sprungzeiten des zugrundeliegenden Koaleszenzprozesses gewährleistet ist. Im Besonderen reicht es aus, wenn die zugehörigen Erwartungen mit denen der entsprechenden Exponentialverteilungen übereinstimmen, und die Varianz nicht zu groß wird.

#### 4.11 Satz

Die Aussage von 4.10 gilt auch, wenn man die Verteilungen der  $T_i$  lediglich vorausgesetzt wird, dass

$$ET_i = \frac{2}{i(i-1)}, \quad (4.31)$$

$$\lim_{n \rightarrow \infty} n^2 \sum_{k=0}^{\lfloor nx \rfloor} \text{Var}(T_{n-k}) = 0 \quad \forall x \in (0, 1). \quad (4.32)$$

gilt.

*Beweis.* Wir beginnen mit der Feststellung, dass für festes  $x_0 \in (0, 1)$  und  $m \in \mathbb{N}$  stets ein  $n_0 \in \mathbb{N}$  zu finden ist, so dass  $n - \lfloor nx_0 \rfloor \geq m$  für alle  $n \geq n_0$  gilt. Vermöge der

Definition der unteren Gaußklammer erhalten wir  $\lfloor y \rfloor \leq y$  für alle  $y \in \mathbb{R}$  und damit  $n - \lfloor nx_0 \rfloor \geq n - nx_0 = n(1 - x_0)$ . Es reicht nun die Bemerkung, dass  $y \rightarrow (1 - x_0)y$  eine lineare Funktion mit positiver Steigung ist.

Wir betrachten erneut (4.14) und erhalten

$$\begin{aligned}
 nZ_n &\stackrel{\sim}{=} \sum_{k=0}^{\tau_n} nT_{n-k} \\
 &= \sum_{k=0}^{\tau_n} (nT_{n-k} - \mathbb{E}nT_{n-k}) + \sum_{k=0}^{\tau_n} \mathbb{E}nT_{n-k} \\
 &= \text{I} + \text{II}.
 \end{aligned} \tag{4.33}$$

Im Folgenden wird zunächst die Konvergenz von I gegen 0 in Wahrscheinlichkeit gezeigt. Dazu sei  $\epsilon > 0$  und  $x_0 \in (0, 1)$ , dann gilt für die Wahrscheinlichkeit, dass I einen Wert ungleich 0 annimmt

$$P(|I| > \epsilon) = P(|I \mathbb{1}_{\{\tau_n/n > x_0\}}| > \epsilon) + P(|I \mathbb{1}_{\{\tau_n/n \leq x_0\}}| > \epsilon).$$

Seien ferner  $\delta > 0$  und  $x_0 \in (0, 1)$  so gewählt, dass  $P(W > x_0) \leq \frac{\delta}{4}$  gilt. Dies ist möglich, da  $W$  eine Verteilung auf  $[0, 1]$  ist. Aus der Verteilungskonvergenz der  $\tau_n/n$  gegen  $W$  in Verteilung, folgt weiter die Existenz einer natürlichen Zahl  $m_1 \in \mathbb{N}$  derart, dass für alle  $n > m_1$

$$\left| P\left(\frac{\tau_n}{n} > x_0\right) - P(W > x_0) \right| \leq \frac{\delta}{4}$$

gilt und damit insbesondere

$$\begin{aligned}
 P(|I \mathbb{1}_{\{\tau_n/n > x_0\}}| > \epsilon) &\leq P\left(\frac{\tau_n}{n} > x_0\right) \\
 &= \left| P\left(\frac{\tau_n}{n} > x_0\right) - P(W > x_0) + P(W > x_0) \right| \\
 &\leq \frac{\delta}{4} + \frac{\delta}{4} = \frac{\delta}{2}
 \end{aligned}$$

vermöge der Dreiecksungleichung für Beträge.

Für hinreichend großes  $n$  ergibt sich nun

$$\begin{aligned}
 \mathbb{E} (\mathbb{I}_{\{\tau_n/n \leq x_0\}})^2 &= \mathbb{E} \mathbb{I}_{\{\tau_n/n \leq x_0\}} \left( \sum_{n=0}^{\tau_n} (nT_{n-k} - \mathbb{E} nT_{n-k}) \right)^2 \\
 &= \mathbb{E} \sum_{l=0}^{\lfloor nx_0 \rfloor} \mathbb{I}_{\{\tau_n=l\}} \left( \sum_{k=0}^l (nT_{n-k} - \mathbb{E} nT_{n-k}) \right)^2 \\
 &= n^2 \mathbb{E} \sum_{l=0}^{\lfloor nx_0 \rfloor} \mathbb{I}_{\{\tau_n=l\}} \sum_{k=0}^l (T_{n-k} - \mathbb{E} T_{n-k})^2 \\
 &\quad + 2 \sum_{j>k}^l (T_{n-k} - \mathbb{E} T_{n-k}) (T_{n-j} - \mathbb{E} T_{n-j}) \\
 &= n^2 \sum_{l=0}^{\lfloor nx_0 \rfloor} \mathbb{P}(\tau_n = l) \left( \sum_{k=0}^l \text{Var}(T_{n-k}) + 2 \sum_{j>k}^l \text{Cov}(T_{n-k}, T_{n-j}) \right) \\
 &\leq n^2 \sum_{k=0}^{\lfloor nx_0 \rfloor} \text{Var}(T_{n-k}),
 \end{aligned}$$

wobei benutzt wurde, dass die  $T_i$  stochastisch unabhängig und ferner unabhängig von  $\tau_n$  sind. Unter Verwendung der Voraussetzung an die Varianzen folgt damit die Konvergenz von  $\mathbb{I} \mathbb{I}_{\{\tau_n/n \leq x_0\}} \xrightarrow{L_2} 0$  für  $n \rightarrow \infty$ . Eine Anwendung der Markov-Ungleichung liefert desweiteren damit auch die stochastische Konvergenz von  $\mathbb{I} \mathbb{I}_{\{\tau_n/n \leq x_0\}}$  gegen 0 vermöge

$$\mathbb{P} (|\mathbb{I} \mathbb{I}_{\{\tau_n/n \leq x_0\}}| \geq \nu) \leq \frac{1}{\nu^2} \mathbb{E} (|\mathbb{I} \mathbb{I}_{\{\tau_n/n \leq x_0\}}|)^2 \rightarrow 0$$

für  $n \rightarrow \infty$  und  $\nu > 0$  und damit die Existenz einer natürlichen Zahl  $m_2 \in \mathbb{N}$  derart, dass für alle  $n > m_2$

$$\mathbb{P} (|\mathbb{I} \mathbb{I}_{\{\tau_n/n \leq x_0\}}| > \epsilon) \leq \frac{\delta}{2}$$

gilt. Damit gilt

$$\mathbb{P} (|\mathbb{I}| > \epsilon) \leq \mathbb{P} (|\mathbb{I} \mathbb{I}_{\{\tau_n/n \leq x_0\}}| > \epsilon) + \mathbb{P} \left( \frac{\tau_n}{n} > x_0 \right) \leq \delta,$$

für alle  $n > \max\{m_1, m_2\}$ . Dabei sind  $m_1, m_2$  abhängig von  $\delta$ , aber da  $\delta > 0$  beliebig war, folgt die stochastische Konvergenz von  $\mathbb{I}$  gegen 0.

Für II gilt ferner nach Voraussetzung

$$\begin{aligned}
 \text{II} &= n \sum_{k=0}^{\tau_n} \mathbb{E} T_{n-k} \\
 &= n \sum_{k=0}^{\tau_n} \frac{2}{(n-k)(n-k-1)} \\
 &= 2n \sum_{k=0}^{\tau_n} \left( \frac{1}{n-k-1} - \frac{1}{n-k} \right) \\
 &= 2n \left( \frac{1}{n-\tau_n-1} - \frac{1}{n} \right) \\
 &= \frac{2}{1-\tau_n/n-1/n} - 2 \xrightarrow{d} \frac{2}{1-W} - 2 = Z,
 \end{aligned}$$

also die Verteilungskonvergenz von II gegen  $Z$  und damit zusammen mit der stochastischen Konvergenz von I gegen 0 ebenso die Verteilungskonvergenz von  $nZ_n \xrightarrow{d} Z$  für  $n \rightarrow \infty$  vermöge des Satzes von Slutsky (vgl. Satz 36.12 in [2]).  $\square$

Der Beweis basiert also auf der Aufteilung der alternativen Darstellung gemäß (4.14) in zwei Teile, von denen einer stochastisch gegen 0 konvergiert, und der andere gerade in Verteilung gegen die Grenzverteilung  $Z$ . Für die Varianz von  $nZ_n$  notieren wir numehr:

#### 4.12 Bemerkung

Gegeben die Voraussetzungen und Bezeichnungen aus 4.11, so gilt

$$\text{Var}(nZ_n) = \text{Var}(\text{I}) + \text{Var}(\text{II}). \quad (4.34)$$

Wir beweisen stattdessen allgemeiner:

#### 4.13 Proposition

Sei  $(\Omega, \mathcal{A}, P)$  ein Wahrscheinlichkeitsraum und  $X = (X_k)_{k \in \mathbb{N}_0} : (\Omega, \mathcal{A}, P) \rightarrow (\mathbb{R}, \mathcal{B}(\mathbb{R}))$  eine Familie unabhängiger, quadratisch integrierbarer Zufallsvariablen, und desweiteren  $N : (\Omega, \mathcal{A}, P) \rightarrow (\mathbb{N}_0, \mathcal{P}(\mathbb{N}_0))$  eine von  $(X_k)_k$  unabhängige, integrierbare Zufallsvariable mit Werten in  $\mathbb{N}_0$ . Ist  $N$  beschränkt, so gilt

$$\text{Var} \left( \sum_{k=0}^N X_k \right) = \text{Var} \left( \sum_{k=0}^N (X_k - \mathbb{E} X_k) \right) + \text{Var} \left( \sum_{k=0}^N \mathbb{E} X_k \right). \quad (4.35)$$

Darüber hinaus erhalten wir ferner

$$\text{Var} \left( \sum_{k=0}^N (X_k - \text{E}X_k) \right) = \text{E}_N \left( \sum_{k=0}^N \text{Var}(X_k) \right) \quad (4.36)$$

$$\text{Var} \left( \sum_{k=0}^N \text{E}X_k \right) = \text{Var}_N \left( \sum_{k=0}^N \text{E}X_k \right), \quad (4.37)$$

wobei mit  $\text{E}_N$  beziehungsweise  $\text{Var}_N$  die Erwartung beziehungsweise die Varianz bezüglich der Verteilung von  $N$  bezeichnet sei.

*Beweis.* Gemäß der Formel für die bedingte Varianz (vgl. Seite 151 in [18]) gilt

$$\text{Var} \left( \sum_{k=0}^N X_k \right) = \text{E}_N \left( \text{Var} \left( \sum_{k=0}^N X_k | N \right) \right) + \text{Var}_N \left( \text{E} \left( \sum_{k=0}^N X_k | N \right) \right). \quad (4.38)$$

Bezeichne mit  $S_N((X_k)_k) = \sum_{k=0}^N X_k$ . Dann gilt für die bedingte Varianz von  $S_N((X_k)_k)$  gegeben  $N$  vermöge der Unabhängigkeit der beteiligten Zufallsvariablen

$$\begin{aligned} & \text{Var}(S_N((X_k)_k) | N = n) \\ &= \text{Var}(S_n((X_k)_k)) \\ &= S_n((\text{Var}(X_k))_k) \\ &= S_n((\text{Var}(X_k - \text{E}X_k))_k) + S_n((\text{Var}(\text{E}X_k))_k). \end{aligned} \quad (4.39)$$

Für die bedingte Erwartung von  $S_N((X_k)_k)$  gegeben  $N$  ergibt sich ferner ebenfalls aufgrund der Unabhängigkeit der beteiligten Zufallsvariablen

$$\begin{aligned} & \text{E}(S_N((X_k)_k) | N = n) \\ &= \text{E}(S_n((X_k)_k)) \\ &= S_n((\text{E}X_k)_k) \\ &= S_n((\text{E}(X_k - \text{E}X_k))_k) + S_n((\text{E}X_k)_k). \end{aligned} \quad (4.40)$$

Zusammengefasst erhalten wir damit

$$\text{Var}(S_N((X_k)_k)) = \text{E}_N(S_N((\text{Var}X_k)_k)) + \text{Var}_N(S_N((\text{E}X_k)_k)).$$

Die Behauptung ergibt sich unter nochmaliger Anwendung der Formel für die bedingte Varianz für die Varianz von  $S_N((X_k - \text{E}X_k)_k)$  beziehungsweise  $S_N((\text{E}X_k)_k)$  vermöge der Feststellungen  $\text{E}(S_N((X_k - \text{E}X_k)_k) | N = n) = 0$  und  $\text{Var}(S_N((\text{E}X_k)_k) | N = n) = 0$ .  $\square$

#### 4.14 Korollar

Für die Varianz von  $nZ_n$  ergibt sich damit

$$\text{Var}(nZ_n) = n^2 \mathbb{E}_{\tau_n} \left( \sum_{k=0}^{\tau_n} \text{Var}(T_{n-k}) \right) + n^2 \text{Var}_{\tau_n} \left( \sum_{k=0}^{\tau_n} \mathbb{E}T_{n-k} \right). \quad (4.41)$$

Mit Rückblick auf 4.6 können wir ferner feststellen, dass das asymptotische Verhalten von  $\text{Var}(nZ_n)$  durch das Verhalten von  $\text{Var}(\mathbb{E}T_i)$  dominiert wird, wenn sich die Summe der Varianzen der  $T_i$  geeignet verhält.

Ferner lässt sich nunmehr eine hinreichende Bedingung für die Erfüllung von (4.32) in 4.11 angeben (vgl. ebenfalls [7]):

#### 4.15 Korollar

Gegeben eine Familie unabhängiger Zufallsvariablen  $(T_i)_{i>1}$ , mit  $\mathbb{E}T_i = i(i-1)/2$  und  $\text{Var}(T_i) = (\mathbb{E}T_i)^2$ , so gilt die Aussage von 4.10; insbesondere konvergiert dann  $nZ_n$  gemäß der Definition in (4.14) in Verteilung gegen eine Verteilung, deren Dichte durch  $x \rightarrow 8/(2+x)^3$  gegeben ist.

*Beweis.* Seien  $T_i$ ,  $i \geq 2$  mit  $\mathbb{E}T_i = \binom{i}{2}$  und  $\text{Var}(T_i) = (\mathbb{E}T_i)^2$ . Sei ferner  $x_0 \in (0, 1)$ . Dann können wir ein  $m \in \mathbb{N}$  derart finden, dass  $n - \lfloor nx_0 \rfloor \geq 2$  für alle  $n \geq m$  gilt. Dann erhalten wir

$$\begin{aligned} \frac{n^2}{4} \sum_{k=0}^{\lfloor nx_0 \rfloor} \text{Var}(T_{n-k}) &= \frac{n^2}{4} \sum_{k=n-\lfloor nx_0 \rfloor}^n \text{Var}(T_k) \\ &= \frac{n^2}{(n-1)^2 n^2} + \frac{n^2}{(n-2)^2 (n-1)^2} + \cdots + \frac{n^2}{(n - \lfloor nx_0 \rfloor - 1)^2 (n - \lfloor nx_0 \rfloor)^2} \\ &\leq \frac{n^2(\lfloor nx_0 \rfloor + 1)}{(n - \lfloor nx_0 \rfloor - 1)^4} \leq \frac{n^3 + n^2}{(n(1 - x_0) - 1)^4} \rightarrow 0, \end{aligned}$$

für  $n \rightarrow \infty$ . Damit sind alle Voraussetzungen aus 4.11 erfüllt; insbesondere gilt damit die Konvergenz von  $nZ_n$  gegen eine Verteilung, deren Dichte durch  $x \rightarrow 8/(2+x)^3$  gegeben ist.  $\square$

In Bezug auf die Interpretation der Länge eines zufällig gewählten Zweiges im Hinblick auf die Frage nach einem Test auf neutrale Selektion, analog zu [12] notieren wir ebenfalls zunächst, dass man den Koaleszenzprozess einfach um neutrale Mutation unter Annahme des »Infinite Allele«, oder des »Infinite Sites« Modells erweitern kann, indem man

einen unabhängigen Poisson-Prozess mit Rate  $\theta/2$  wählt, um damit nachträglich Mutationszeitpunkte zu generieren (vgl. [9] oder [16]). Der Parameter  $\theta$  bezeichnet dabei die skalierte Mutationsrate.

Damit genügt die Anzahl der Mutationen auf einem Zweig der Länge  $l$  einer Poisson-Verteilung mit Rate  $l\theta/2$ .

Für einen externen Zweig eines Koaleszenzbaumes mit Länge  $Z_n$  bezeichnet demgemäß  $M(2Z_n)$  die Anzahl der Mutationen, die auf dem Teilbaum eines zufällig gewählten Individuums und seines nächsten Verwandten stattfinden. Als Anwendung von 4.10 ergibt sich:

#### 4.16 Korollar

Für die Anzahl der Mutationen auf einem zufällig gewählten externen Zweig eines Koaleszenzbaumes gilt  $M(2nZ_n) \xrightarrow{d} M(2Z)$ , wobei die Verteilung von  $M(2Z)$  durch

$$\begin{aligned} P(M(2Z/n) = k) &= \int P(M(2x/n) = k) dP^Z(dx) \\ &= \int \frac{x^k \theta^k}{n^k k!} e^{-x\theta/n} dP^Z(dx) \\ &= \frac{(\theta/n)^k}{k!} \int_0^\infty e^{-\theta x/n} \frac{8x^k}{(2+x)^3} dx \end{aligned} \quad (4.42)$$

für  $k \in \mathbb{N}_0$  gegeben ist.

# A. Appendix

An dieser Stelle seien einige Aussagen zusammengefasst, auf die im bisherigen Verlauf verwiesen wurde, die aber im Textverlauf nicht zweckmäßig untergebracht werden konnten.

## A.1 Lemma

Sei  $k \in \mathbb{N}$  und seien  $a, c \in \mathbb{R}$ . Dann gilt

$$\lim_{x \rightarrow \infty} a \frac{\ln^k(x)}{x} + c = c. \quad (\text{A.1})$$

*Beweis.* Da sowohl  $x$  als auch  $\ln^k(x)$  für  $x \rightarrow \infty$  bestimmt gegen  $\infty$  divergieren, lässt sich die Regel von de l'Hospital anwenden (siehe zum Beispiel §16, Satz 9 in [11]). Es gilt dann für  $k > 1$

$$\lim_{x \rightarrow \infty} \frac{\ln^k(x)}{x} = \lim_{x \rightarrow \infty} \frac{\frac{d}{dx} \ln^k(x)}{\frac{d}{dx} x} = \lim_{x \rightarrow \infty} \frac{\frac{k \ln^{k-1}(x)}{x}}{1} = \lim_{x \rightarrow \infty} \frac{k \ln^{k-1}(x)}{x},$$

und somit durch iteratives Anwenden der Regel von L'Hospital und unter Verwendung von  $\frac{d}{dx} \ln(x) = 1/x$

$$\lim_{x \rightarrow \infty} a \frac{\ln^k(x)}{x} + c = \lim_{x \rightarrow \infty} a \frac{k!}{x} + c = c.$$

□

## A.2 Lemma

Für  $x > 0$  gilt

$$x - \frac{x^2}{2} \leq \ln(1 + x) \leq x.$$

*Beweis.* Sei  $0 < x \leq 1$ , dann gilt

$$\ln(1 + x) = \sum_{n=1}^{\infty} (-1)^{n+1} \frac{x^n}{n},$$

## A. Appendix

---

als Reihenentwicklung des Logarithmus mit Konvergenzradius 1. Weiterhin gilt für jedes  $k \in \mathbb{N}$

$$\left| \frac{x^k}{k} \right| > \left| \frac{x^{k+1}}{k+1} \right|$$

und damit für  $k \in \mathbb{N}$

$$(-1)^{2k+1} \frac{x^{2k}}{2k} + (-1)^{2k+2} \frac{x^{2k+1}}{2k+1} < 0,$$

beziehungsweise

$$(-1)^{2k+2} \frac{x^{2k+1}}{2k+1} + (-1)^{2k+3} \frac{x^{2k+2}}{2k+2} > 0.$$

Daraus folgt

$$\sum_{n=2}^{\infty} (-1)^{n+1} \frac{x^n}{n} \leq 0 \text{ bzw. } \sum_{n=3}^{\infty} (-1)^{n+1} \frac{x^n}{n} \geq 0,$$

und damit wiederum

$$\begin{aligned} x - \frac{x^2}{2} &\leq x - \frac{x^2}{2} + \sum_{n=3}^{\infty} (-1)^n + 1 \frac{x^n}{n} \\ &= \ln(1+x) \\ &= x + \sum_{n=2}^{\infty} (-1)^{n+1} \frac{x^n}{n} \leq x. \end{aligned}$$

Sei nun  $x > 1$ . Beobachte, dass  $f(x) = -\frac{x^2}{2} + x$  ein globales Maximum bei  $x_0 = 1$  besitzt und ferner  $f(1) = \frac{1}{2} \leq \ln(2)$  gilt. Die zweite Ungleichung gilt vermöge der Beobachtung  $\ln(1+x) \leq x \Leftrightarrow 1+x \leq e^x$  und  $2 \leq e$ .

□

### A.3 Lemma

Sei  $x \in \mathbb{R}$ , dann gilt

$$\lim_{n \rightarrow \infty} \left(1 + \frac{x}{n}\right)^n = e^x \tag{A.2}$$

*Beweis.* Sei  $x \in \mathbb{R}$  gegeben, ferner sei  $x \neq 0$ . Setze  $f_x(n) \stackrel{\text{def}}{=} (1 + \frac{x}{n})^n$  und betrachte

$$\lim_{n \rightarrow \infty} \ln(f_x(n)^n) = \lim_{n \rightarrow \infty} n \ln(f_x(n)) = \lim_{n \rightarrow \infty} \frac{\ln(f_x(n))}{n^{-1}}.$$

Damit sind die Voraussetzungen für den Satz von de l'Hospital (§16, Satz 9 in [11]) gegeben und es gilt  $\lim_{n \rightarrow \infty} \ln((1 + x/n)^n) = x$ . □

**A.4 Lemma**

Für die Summe der natürlichen Zahlen von 1 bis  $n$ , ihrer Quadrate, beziehungsweise ihrer dritten Potenzen gelten

$$\sum_{k=1}^n k = \frac{n(n+1)}{2}, \quad (\text{A.3})$$

$$\sum_{k=1}^n k^2 = \frac{n(n+1)(2n+1)}{6}, \quad (\text{A.4})$$

$$\sum_{k=1}^n k^3 = \frac{n^4 + 2n^3 + n^2}{4}. \quad (\text{A.5})$$

**A.5 Lemma**

Es seien  $(X_k)_{1 \leq k \leq n}$  unabhängige, jeweils  $\text{Exp}(\lambda_k)$ -verteilte Zufallsvariablen auf einem Wahrscheinlichkeitsraum  $(\Omega, \mathcal{A}, P)$ ,  $\lambda_k > 0$ ,  $1 \leq k \leq n$ . Dann ist  $X \stackrel{\text{def}}{=} \min\{X_k : 1 \leq k \leq n\}$  ebenfalls exponentialverteilt mit Parameter  $\lambda = \sum_{k=1}^n \lambda_k$ . Die Wahrscheinlichkeit, dass  $X_j$ ,  $1 \leq j \leq n$  das Minimum annimmt, ergibt sich als

$$P(X_j = \min\{X_k : 1 \leq k \leq n\}) = \frac{\lambda_j}{\lambda_1 + \dots + \lambda_n}.$$

*Beweis.* Wähle hierzu  $x > 0$  beliebig und betrachte

$$\begin{aligned} P(X > x) &= P(X_1 > x, X_2 > x, \dots, X_n > x) \\ &= \prod_{k=1}^n P(X_k > x) \\ &= \prod_{k=1}^n \exp(-x\lambda_k) = \exp\left(-x \sum_{k=1}^n \lambda_k\right). \end{aligned}$$

Damit entspricht die Verteilungsfunktion von  $X$  der einer Exponentialverteilung mit Parameter  $\lambda$ . Für den zweiten Teil notieren wir

$$\begin{aligned} P(X_j = \min\{X_k : 1 \leq k \leq n\}) &= P(X_j < X_k, j \neq k, 1 \leq k \leq n) \\ &= E_{X_j}(\mathbb{1}_{\{X_j < X_k : j \neq k, 1 \leq k \leq n\}} | X_j) \\ &= \int_0^\infty \lambda_j e^{-\lambda_j t} \prod_{\substack{j \neq k \\ 1 \leq k \leq n}} P(X_j > t) dt \\ &= \int_0^\infty \lambda_j e^{-(\lambda_1 + \dots + \lambda_n)t} dt \\ &= \frac{\lambda_j}{\lambda_1 + \dots + \lambda_n}. \end{aligned}$$

□

**A.6 Proposition**

Sei  $(\Omega, \mathcal{A}, P)$  ein Wahrscheinlichkeitsraum, und seien  $X_1, X_2: (\Omega, \mathcal{A}, P) \rightarrow (\mathbb{R}, \mathcal{B})$  unabhängige, exponentialverteilte Zufallsvariablen mit Parameter  $\lambda_i > 0$ , das heißt  $X_i \sim \text{Exp}(\lambda_i)$ , sowie  $B: (\Omega, \mathcal{A}, P) \rightarrow (\{0, 1\}, \mathcal{P}(\{0, 1\}))$  eine von  $X_1, X_2$  unabhängige, bernoulliverteilte Zufallsvariable mit Parameter  $p \in (0, 1)$ , das heißt  $B \sim \text{B}(1, p)$ . Unter der Voraussetzung  $\lambda_1 > \lambda_2$  und  $p = \frac{\lambda_1 - \lambda_2}{\lambda_1}$ , gilt

$$X_1 + BX_2 \stackrel{\cong}{\sim} \text{Exp}(\lambda_2),$$

das heißt,  $X_1 + BX_2$  genügt einer Exponentialverteilung mit Parameter  $\lambda_2$ .

*Beweis.* Unter der Berücksichtigung von

$$f_X(x) = \lambda e^{-\lambda x} \mathbb{1}_{[0, \infty)}(x) \quad F_X(x) = 1 - e^{-\lambda x} \mathbb{1}_{[0, \infty)}(x),$$

wobei  $f_X$  die Dichte- und  $F_X$  die Verteilungsfunktion für eine Zufallsvariable  $X \sim \text{Exp}(\lambda)$  bezeichne, gilt für die Verteilungsfunktion von  $X_1 + BX_2$

$$\begin{aligned} & \text{P}(X_1 + BX_2 \leq t) \\ &= \text{P}(N = 0) \text{P}(X_1 + BX_2 \leq t | B = 0) + \text{P}(N = 1) \text{P}(X_1 + BX_2 \leq t | B = 1) \\ &= (1 - p) \left( 1 - e^{-\lambda_1 t} \right) + p (\text{E}_{X_1} (\text{P}(X_1 + BX_2 \leq t | B = 1, X_1))) \\ &= (1 - p) \left( 1 - e^{-\lambda_1 t} \right) + p \int_0^\infty \left( 1 - e^{-\lambda_2(t-s)} \right) \mathbb{1}_{\{t-s \geq 0\}} \lambda_1 e^{-\lambda_1 s} ds \\ &= (1 - p) \left( 1 - e^{-\lambda_1 t} \right) + p \left[ 1 - e^{-\lambda t} - \frac{\lambda_1}{\lambda_2 - \lambda_1} \left( e^{-\lambda_1 t} - e^{-\lambda_2 t} \right) \right] \\ &= (1 - p) \left( 1 - e^{-\lambda_1 t} \right) + p \frac{\lambda_1}{\lambda_1 - \lambda_2} \left( e^{-\lambda_1 t} - e^{-\lambda_2 t} \right). \end{aligned}$$

Mit Erinnerung an die Voraussetzung  $p = \frac{\lambda_1 - \lambda_2}{\lambda_1}$  folgt somit die Behauptung. □

# Literaturverzeichnis

- [1] ALSMEYER, G.: *Stochastische Prozesse, Teil 2*. Unveröffentlichtes Skript.
- [2] ALSMEYER, G.: *Wahrscheinlichkeitstheorie*. Skripten zur Mathematischen Statistik, Nr. 30, 2005. Institut für Mathematische Statistik, Fachbereich Mathematik der Westfälischen Wilhelms-Universität Münster.
- [3] ASMUSSEN, S.: *Applied Probability and Queues*. Springer, 2. Aufl., 2003.
- [4] BERESTYCKI, N.: *Recent Progress in Coalescent Theory*. *Ensaio Matemáticos*, 16:1–193, 2009.
- [5] BERTOIN, J.: *Random Fragmentation and Coagulation Processes*, Bd. 102 d. Reihe *Cambridge Studies in Advanced Mathematics*. Cambridge University Press, 13. Aufl., 2006.
- [6] BLUM, M. G. B. und O. FRANÇOIS: *External branch length and minimal clade size under the neutral coalescent*. *Advances in Applied Probability*, 37(3):647–662, 2005.
- [7] CALIEBE, A., R. NEININGER, M. KRAWCZACK und U. RÖSLER: *On the length distribution of external branches in coalescence trees: Genetic diversity within species*. *Theoretical Population Biology*, 72:245–252, 2007.
- [8] CHUNG, K. L. und J. B. WALSH: *Markov Processes, Brownian Motion, and Time Symmetry*. Springer, 2. Aufl., 2005.
- [9] DURRETT, R.: *Probability Models for DNA Sequence Evolution*. Springer, 2. Aufl., 2008.
- [10] EVANS, S. N. und J. PITMAN: *Construction of Markovian coalescents*. *Ann. Inst. Henri Poincaré*, 34(3):339–383, 1998.
- [11] FORSTER, O.: *Analysis 1*. Vieweg & Sohn Verlag, 7. Aufl., Juni 2004.
- [12] FU, Y.-X. und W.-H. LI: *Statistical Tests of Neutrality of Mutations*. *Genetics*, 133(3):693–709, 1993.
- [13] JANSON, S. und G. KERSTING: *The external lengths in Kingman's coalescent*. arXiv:1004.5011v2 [math.PR], 2011.

- [14] KINGMAN, J.: *The Coalescent*. Stochastic Processes and their Applications, 13:235–248, 1982.
- [15] KINGMAN, J.: *On the Genealogy of Large Populations*. Journal of Applied Probability, 19:27–43, 1982.
- [16] NORDBORG, M.: *Coalescent Theory*. Techn. Ber., Department of Genetics, Lund University, 2000.
- [17] RAUCH, E. M. und Y. BAR-YAM: *Theory predicts the uneven distribution of genetic diversity within species*. Nature, 431:449–452, 2004.
- [18] RICE, J. A.: *Mathematical Statistics And Data Analysis*. Duxbury Press, 3. Aufl., 2006.
- [19] TAVARÉ, S.: *Ancestral Inference in Population Genetics*. Springer, 2004.

Ich versichere, dass ich die vorliegende Arbeit selbständig angefertigt und keine anderen als die im Literaturverzeichnis aufgeführten Quellen und Hilfsmittel verwendet habe.

Ahaus, den 21. September 2012

Thomas Uckelmann