

Horton Strahler Zahlen

Manuel Inselmann

3.11.2011

1 Einführung

In diesem Seminarvortrag wird als Hauptresultat gezeigt, dass $P_n(|S_n - \log_4 n| \geq \epsilon) \leq \frac{D}{4^\epsilon}$ für ein $D > 0$ und alle $\epsilon > 0$ gilt, wobei P_n die Gleichverteilung auf der Menge aller Bäume mit n Knoten und $S_n(T)$ die Horton-Strahler Zahl eines Baumes T sei.

Zunächst sei an den Begriff eines Baumes erinnert:

Definition 1.1. $2^{<\mathbb{N}_0} := \bigcup_{n \in \mathbb{N}_0} \{0, 1\}^n$ ist der vollständige binäre Baum.

Die Elemente von $2^{<\mathbb{N}_0}$ sind also von der Form

$(i_0, i_1, \dots, i_{n-1})$ mit $i_k \in \{0, 1\}$. Das einzige Element aus $\{0, 1\}^0$ sei mit \emptyset bezeichnet.

Für $t = (i_0, i_1, \dots, i_{n-1}) \in 2^{<\mathbb{N}_0}$ und $s = (j_0, j_1, \dots, j_{m-1}) \in 2^{<\mathbb{N}_0}$ sei $t \wedge s = (i_0, i_1, \dots, i_{n-1}, j_0, j_1, \dots, j_{m-1})$, (insbesondere gelte $t \wedge \emptyset = \emptyset \wedge t = t$).

Außerdem soll $s \leq t$ bedeuten, dass es ein $u \in 2^{<\mathbb{N}_0}$ gibt mit $s \wedge u = t$ und $s < t$ soll heißen, dass $s \leq t$ und $s \neq t$ gilt.

Nun können wir definieren, was ein Baum ist:

Definition 1.2. Eine endliche Teilmenge T von $2^{<\mathbb{N}_0}$ heißt Baum, falls für alle $t \in T$ und $s \in 2^{<\mathbb{N}_0}$ mit $s \leq t$ folgt, dass $s \in T$ gilt. Die $t \in T$ heißen Knoten von T .

Definition 1.3. $\Omega = \{T \subset 2^{<\mathbb{N}_0} \mid T \text{ ist Baum}\}$

Definition 1.4. Sei T ein Baum und $t \in 2^{<\mathbb{N}_0}$.

Definiere $T_t := \{s \in 2^{<\mathbb{N}_0} \mid t \wedge s \in T\}$

und $t \wedge T := \{t \wedge s \mid s \in T\}$.

Definition 1.5. $r : \Omega \setminus \{\emptyset\} \rightarrow \Omega$

$$r(T) = \begin{cases} \emptyset & \text{falls } T = \{\emptyset\} \\ r(T_i) & \text{falls } i \in T \text{ und } (1-i) \notin T \text{ (} i \in \{0, 1\} \text{)} \\ \{\emptyset\} \cup (0) \wedge r(T_{(0)}) \cup (1) \wedge r(T_{(1)}) & \text{falls } (0) \in T \text{ und } (1) \in T \end{cases}$$

Definition 1.6. Die Abbildung $S : \Omega \rightarrow \mathbb{N}_0$ ordnet jedem Baum seine Horton-Strahler-Zahl zu. Sie ist rekursiv definiert durch:

$$S(\emptyset) = 0$$

$$S(T) = S(r(T)) + 1.$$

Also ist $S(T)$ das minimale n , für das $r^{\circ n}(T) = \emptyset$ ist.

Mit Induktion nach der Anzahl der Knoten zeigt man leicht, dass man $S(T)$

rekursiv auch wie folgt definieren kann:

$$S(\emptyset) = 0$$

$$S(T) = \max\{S(T_{(0)}), S(T_{(1)})\} + 1_{\{S(T_{(0)})=S(T_{(1)})\}}.$$

Beispielsweise ist $S(T) = 1$ genau dann, wenn (T, \leq) linear ist. Das andere Extrembeispiel ist $T = \cup_{k < n} \{0, 1\}^k$ mit $S(T) = n$. Man beachte, dass in diesem Fall $|T| = 2^n - 1$ gilt.

Allgemein gilt für alle $T \in \Omega$: $S(T) \leq \log_2(|T| + 1)$,
denn dies ist klar für $|T| \in \{0, 1\}$ und für $S(T_{(0)}) \neq S(T_{(1)})$ und ansonsten gilt:
 $S(T) \leq S(T_{(0)}) + 1 \leq \log_2\left(\frac{|T|-1}{2} + 1\right) + 1 = \log_2(|T| + 1)$
(denn $\min\{|T_{(0)}|, |T_{(1)}|\} \leq \frac{|T|-1}{2}$).

Vorarbeiten

In diesem Abschnitt wird der die Funktion r , die ja gemäß $S(T) = S(r(T)) + 1$ mit S zusammenhängt, weiter untersucht. Dazu wird die Funktion l eingeführt, die jedem Baum die Anzahl seiner Blätter zuordnet. Für l gilt nämlich $|r(T)| = l(T) - 1$ und eine genauere Analyse von l ist der letztlich der Schlüssel zum Beweis des Hauptresultats.

Definition 1.7. Sei T ein Baum und $t \in 2^{<\mathbb{N}_0}$. Dann heißt t externer Knoten von T , falls $t \notin T$ und $\forall s < t$ $s \in T$ gilt.
Weiter sei $E(T) := \{t \in 2^{<\mathbb{N}_0} | t \text{ ist externer Knoten von } T\}$
und $e(T) = |E(T)|$.

Bemerkung 1.8. Für alle $T \in \Omega$ gilt: $e(T) = |T| + 1$.

Beweis. $T = \emptyset$ ist offensichtlich.

Ansonsten gilt nach Induktion nach der Anzahl der Knoten:

$$e(T) = e(T_{(0)}) + e(T_{(1)}) = |T_{(0)}| + |T_{(1)}| + 2 = |T| + 1. \quad \square$$

Definition 1.9. Sei T ein Baum und $t \in 2^{<\mathbb{N}_0}$. Dann heißt t Blatt von T genau dann, wenn $t \in T$ und $t \frown (0), t \frown (1) \notin T$ gilt.

Sei $L(T) := \{t \in 2^{<\mathbb{N}_0} | t \text{ ist ein Blatt von } T\}$ und $l(T) = |L(T)|$.

Bemerkung 1.10. Sei $T \in \Omega \setminus \{\emptyset\}$. Dann gilt $e(r(T)) = l(T)$

Beweis. Der Beweis erfolgt wieder über Induktion nach der Anzahl der Knoten. Der Fall $T = \{\emptyset\}$ ist klar.

Für alle anderen T gilt: $l(T) = l(T_{(0)}) + l(T_{(1)}) = e(r(T))$. □

Bemerkung 1.11. Zusammengesetzt ergibt sich: $|r(T)| = l(T) - 1$.

Definition 1.12. Für $n \in \mathbb{N}_0$ sei $\Omega_n := \{T \in \Omega | |T| = n\}$ und P_n die Gleichverteilung auf Ω_n . Ferner sei r_n die Einschränkung von r auf Ω_n .

Lemma 1.13. Es gilt $\mathbb{P}(r_n = \cdot | |r_n| = k) = P_k(\cdot)$

Beweis. Es ist zu zeigen, dass jedes $T \in \Omega_k$ unter r_n gleich viele Urbilder besitzt.

Definiere dazu $i_k : \Omega_k \rightarrow \Omega_{2k+1}$;

$T \mapsto T \cup E(T)$,

sowie $i : \Omega \rightarrow \Omega$;

$T \mapsto T \cup E(T)$.

Dann gilt $r \circ i_k = id_{\Omega_k}$. Dies zeigt, dass jeder Baum $T \in \Omega_k$ genau ein r -Urbild in $i(\Omega_k)$ besitzt.

Sei nun $q : \Omega \rightarrow \Omega$

$$q(T) = \begin{cases} \{\emptyset\} & \text{falls } T = \emptyset \\ \{\emptyset\} & \text{falls } T = \{\emptyset\} \\ q(T_i) & \text{falls } i \in T \text{ und } (1-i) \notin T \\ \{\emptyset\} \cup 0 \frown q(T_0) \cup 1 \frown q(T_1) & \text{falls } 0 \in T \text{ und } 1 \in T \end{cases}$$

Sei q_n die Einschränkung von q auf Ω_n .

q_n ist für $n > 0$ also die Abbildung, die in einem Baum genau diejenigen Knoten „weglässt“, die genau ein Kind besitzen.

Damit folgt, dass $q(\Omega) = i(\Omega)$ gilt, sowie andererseits $r_n = r \circ q_n$. Wenn nun $Q \in \Omega_n$ ein r -Urbild zu $T \in \Omega_k$ ist, so gilt $q(Q) = i_k(T)$. Es reicht also zu zeigen, dass jeder Baum $i_k(T)$ unter q gleich viele Urbilder in Ω_n besitzt. Dies folgt aber daraus, dass jedes q -Urbild aus $i_k(T)$ hervorgeht, indem über jeden Knoten, der kein Blatt ist, eine lineare Folge von Knoten aufgesetzt wird und der Baum dann wie er vorher war, fortgesetzt wird (formaler: $T \mapsto t \frown s \frown T_s$, wobei s der linearen Folge entspricht und t dem Knoten, der kein Blatt ist). Um dabei ein Baum mit n Knoten zu erhalten, muss man $n - 2k - 1$ Knoten hinzufügen und hierfür gibt es unabhängig von T immer $\binom{n-1}{2k} 2^{n-2k-1}$ Möglichkeiten. \square

Wegen der Beziehungen $|r(T)| = l(T) - 1$, $\{S(T) > 0\} = \{|r^{\circ k}(T)| > 0\}$ und $S(T) = S(r(T)) + 1$, macht es Sinn, sich nun zunächst mit der Funktion l zu beschäftigen, bzw. mit ihrer Einschränkung auf Ω_n , die mit l_n bezeichnet sei.

Definition 1.14. $Q_{nk} := \{T \in \Omega_n \mid l(T) = k\}$;

$$q_{nk} := |Q_{nk}|$$

$$Q(w, z) = \sum_{n, k \geq 0} q_{nk} w^n z^k.$$

Bemerkung 1.15. Es gilt für $n > 1$ und $k \in \mathbb{N}_0$:

$$q_{nk} = \sum_{n_1+n_2=n-1, k_1+k_2=k} q_{n_1 k_1} q_{n_2 k_2}$$

Beweis. Definiere $+$: $\Omega \times \Omega \rightarrow \Omega$ mit $(T, S) \mapsto \{\emptyset\} \cup (0) \frown T \cup (1) \frown S$

Dann gilt für $n > 1$:

$$Q_{nk} = \bigcup_{n_1+n_2=n-1, k_1+k_2=k} (Q_{n_1 k_1} + Q_{n_2 k_2})$$

Da diese Vereinigung disjunkt ist, folgt die Behauptung. \square

Bemerkung 1.16. Es gilt in einer offenen Umgebung von $(0, 0)$:

$$Q(w, z) = \frac{1 - \sqrt{1 - 4w(wz - w + 1)}}{2w}.$$

Beweis. Es gilt: $q_{00} = 1$, $q_{10} = 0$, $q_{1n} = 0$ für $n > 1$ und $q_{0n} = 0$ für $n > 0$. Hieraus und aus obiger Bemerkung erhält man:

$$\begin{aligned} & (2wQ(w, z) - 1)^2 \\ = & 4 \sum_{n, k \geq 0} \sum_{n_1 + n_2 = n, k_1 + k_2 = k} q_{n_1 k_1} q_{n_2 k_2} w^{n+2} z^k - 4 \sum_{n, k \geq 0} q_{nk} w^{n+1} z^k + 1 \\ & = 1 + 4w^2 - 4w - 4w^2 z = 1 - 4w(wz - w + 1) \end{aligned}$$

$Q'(w, z) := \frac{1 - \sqrt{1 - 4w(wz - w + 1)}}{2w}$ erfüllt diese Gleichung anstelle von $Q(w, z)$ ebenso. Ferner ist Q' in einer Umgebung von $(0, 0)$ in der Form

$$Q'(w, z) = \sum_{n, k \geq 0} q'_{nk} w^n z^k$$

darstellbar, wobei man aus

$$Q'(w, z) = \frac{1 - \sum_{k \geq 0} \binom{\frac{1}{2}}{k} (-1)^k (4w(wz - w + 1))^k}{2w}$$

abliest, dass $q'_{nk} = q_{nk}$ für alle $n \leq 1$ und $k \in \mathbb{N}_0$ gilt.

Da die q'_{nk} für $n > 1$ aber auch obige Rekursionsgleichung erfüllen und diese durch diese Informationen schon vollständig bestimmt sind, folgt $q'_{nk} = q_{nk}$ für alle $n, k \in \mathbb{N}_0$. \square

Bemerkung 1.17. Es gilt für alle $n \in \mathbb{N}_0$:

$$E_n(l_n) = \frac{n(n+1)}{2(2n-1)}, \text{ sowie}$$

$$\text{Var}_n(l_n) = \frac{n(n+1)(n-1)(n-2)}{2(2n-3)(2n-1)^2}.$$

Beweis. Die Behauptungen ergeben sich aus der Beziehung

$$Q(w, z) = \frac{1 - \sqrt{1 - 4w(wz - w + 1)}}{2w}$$

So ist

$$E_n(l_n) = \frac{\sum_{k \geq 0} k q_{nk}}{\sum_{k \geq 0} q_{nk}}$$

und $\sum_{k \geq 0} q_{nk}$ ist der n -te Koeffizient in der Potenzreihenentwicklung von $Q(w, 1) = \frac{1 - \sqrt{1 - 4w}}{2w}$ und $\sum_{k \geq 0} k q_{nk}$ ist der n -te Koeffizient in der Potenzreihenentwicklung

von $\frac{\partial Q}{\partial z}(w, 1) = \frac{w}{\sqrt{1-4w}}$.
Also

$$E_n(l_n) = \frac{\binom{-\frac{1}{2}}{n-1}(-4)^{n-1}}{2\binom{\frac{1}{2}}{n+1}(-4)^n} = \frac{n(n+1)}{2(2n-1)}$$

Analog ist

$$Var_n(l_n) = \frac{\sum_{k \geq 0} k(k-1)q_{nk}}{\sum_{k \geq 0} q_{nk}} + E_n(l_n)(1 - E_n(l_n))$$

und $\sum_{k \geq 0} k(k-1)q_{nk}$ ist der n -te Koeffizient der Potenzreihenentwicklung von

$$\frac{\partial^2 Q}{\partial^2 z}(w, 1) = 2w^3(1-4w)^{-\frac{3}{2}}$$

also $\sum_{k \geq 0} k(k-1)q_{nk} = 2(-4)^{n-3} \binom{-\frac{3}{2}}{n-3}$.

Setzt man dies in $Var_n(l_n) = \frac{\sum_{k \geq 0} k(k-1)q_{nk}}{\sum_{k \geq 0} q_{nk}} + E_n(l_n)(1 - E_n(l_n))$ ein und formt um, erhält man die Behauptung. \square

Hauptresultat

Satz 1.18. *Es gilt für alle $\epsilon \geq 0$ und $n \in \mathbb{N}$:*

$$P_n(S_n > \lceil \log_4 n + \epsilon \rceil) \leq \frac{1}{4^\epsilon}$$

Beweis. Setze $T_k := r^{\circ k}(T)$.

Dann gilt wegen Lemma 1.13 und $\frac{n(n+1)}{2(2n-1)} - 1 \leq \frac{n}{4}$:

$$\begin{aligned} E|T_{k+1}| &= E(l(T_k) - 1)1_{\{|T_k| > 0\}} = E(E(l_j - 1) | |T_k| = j) = EE_j(l_j - 1) = E\left(\frac{j(j+1)}{2(2j-1)} - 1\right)1_{\{j > 0\}} \\ &\leq E\frac{|T_k|}{4} \end{aligned}$$

Induktiv folgt: $E|T_k| \leq \frac{n}{4^k}$.

Wegen $P_n(|T_k| \geq 1) \leq E|T_k|$ und $\{S_n > k\} = \{|T_k| > 0\}$ folgt für $k := \lceil \log_4 n + \epsilon \rceil$:

$$P_n(S_n > \lceil \log_4 n + \epsilon \rceil) \leq \frac{n}{4^{\lceil \log_4 n + \epsilon \rceil}} \leq \frac{1}{4^\epsilon}$$

\square

Satz 1.19. Es gibt ein $C > 0$, so dass für alle $\epsilon \geq 0$

$$P_n(S_n \leq \lfloor \log_4 n - \epsilon \rfloor) \leq \frac{C}{4^\epsilon}$$

gilt.

Beweis. Mit $\text{Var}(X|Y) = E(X^2|Y) - (E(X|Y))^2$ hat man:

$$\text{Var}|T_{k+1}| = \text{Var}(E(|T_{k+1}||T_k|)) + E(\text{Var}(|T_{k+1}||T_k|))$$

Wegen Bemerkung 1.17 und Lemma 1.13 gilt:

$$\begin{aligned} E(\text{Var}(|T_{k+1}||T_k|)) &= E(E(|T_{k+1}|^2|T_k| = j) - E(|T_{k+1}||T_k| = j)^2) \\ &= E\text{Var}(l_j - 1)1_{\{j>0\}} = E \frac{|T_k|(|T_k| + 1)(|T_k| - 1)(|T_k| - 2)}{2(2|T_k| - 3)(2|T_k| - 1)^2} \leq \frac{1}{8}E|T_k| \end{aligned}$$

Nun gilt für

$$X = \frac{1}{4}1_{\{|T_k| \in \{1,2,3\}\}} + 1_{\{|T_k| > 3\}}$$

dass $EX \leq 1$ und andererseits:

$$0 \leq \frac{|T_k|}{4} - X \leq E(|T_{k+1}||T_k|) \leq \frac{|T_k|}{4}$$

Hieraus folgt:

$$\begin{aligned} \text{Var}(E(|T_{k+1}||T_k|)) &= E(E(|T_{k+1}||T_k|)^2) - (E(E(|T_{k+1}||T_k|)))^2 \leq \\ E\left(\frac{|T_k|}{4}\right)^2 - (E\left(\frac{|T_k|}{4} - X\right))^2 &= \text{Var}\frac{|T_k|}{4} + 2E\frac{|T_k|}{4}EX - (EX)^2 \leq \text{Var}\frac{|T_k|}{4} + 2E\frac{|T_k|}{4} \end{aligned}$$

Insgesamt ergibt sich:

$$\text{Var}|T_{k+1}| \leq cE|T_k| + \frac{1}{16}\text{Var}|T_k| \leq \frac{cn}{4^k} + \frac{1}{16}\text{Var}|T_k|$$

(mit $c = \frac{5}{8}$).

Induktiv ergibt sich

$$\text{Var}|T_{k+1}| \leq \frac{cn}{4^k} \frac{1 - 4^{-k-2}}{1 - \frac{1}{4}} \leq \frac{4cn}{3 \cdot 4^k}$$

Wie im Beweis des vorherigen Satzes zeigt man mithilfe von $\frac{n(n+1)}{2(2n-1)} \geq \frac{n}{4}$, dass

$$E|T_{k+1}| \geq E\frac{|T_k|}{4} - 1$$

gilt, also

$$E|T_{k+1}| \geq \frac{n}{4^{k+1}} - \frac{4}{3}$$

Nun kommen wir zur Abschätzung:

$$\begin{aligned} P_n(S_n \leq k) &= P_n(|T_k| = 0) = P_n(|T_k| - E|T_k| = -E|T_k|) \\ &\leq P_n(|T_k| - E|T_k| \geq E|T_k|) \leq \frac{\text{Var}|T_k|}{(E|T_k|)^2} \leq \frac{4cn}{3 \cdot 4^k} \frac{1}{(\frac{n}{4^k} - \frac{4}{3})^2} \end{aligned}$$

Für $k = \lfloor \log_4 n - x \rfloor$ erhält man für $x \geq 1$ (woraus $4^x - \frac{4}{3} > 0$ folgt):

$$P_n(S_n \leq \lfloor \log_4 n - x \rfloor) \leq \frac{4c}{3 \cdot 4^{-x-1}} \frac{1}{(4^x - \frac{4}{3})^2} \leq 12c \frac{1}{4^x}$$

(da $4^x - \frac{4}{3} \geq \frac{2}{3}4^x$ gilt für $x \geq 1$).

Also gilt

$$P_n(S_n \leq \lfloor \log_4 n - x \rfloor) \leq \frac{C}{4^x}$$

für $C = \frac{15}{2}$, falls $x \geq 1$, aber die Behauptung gilt trivialerweise auch für $x < 1$, für jedes $C \geq 4$. \square

Die beiden vorangegangenen Sätze liefern unmittelbar:

Satz 1.20. *Es gibt ein $D > 0$, so dass für alle $x > 0$ gilt:*

$$P_n(|S_n - \log_4 n| \geq x) \leq \frac{D}{4^x}.$$

Korollar 1.21. *Für alle $s > 0$ gilt:*

$$E_n |S_n - \log_4 n|^s = O(1)$$

.

Beweis. Es gilt:

$$\begin{aligned} E_n |S_n - \log_4 n|^s &= \int_0^\infty st^{s-1} P_n(|S_n - \log_4 n| > t) \leq D \int_0^\infty st^{s-1} 4^{-t} = D(\ln 4)^s \int_0^\infty st^{s-1} e^{-t} \\ &= Ds(\ln 4)^s \Gamma(s) < \infty \end{aligned}$$

\square

Korollar 1.22. *Für alle $\lambda < \log 4$ gilt:*

$$E e^{\lambda |S_n - \log_4 n|} < \infty$$

Beweis. Es gilt:

$$\begin{aligned} E e^{\lambda |S_n - \log_4 n|} &\leq \sum_{k=0}^\infty e^{\lambda(k+1)} P_n(k \leq |S_n - \log_4 n| < k+1) \\ &\leq D e^\lambda \sum_{k=0}^\infty \left(\frac{e^\lambda}{4}\right)^k = \frac{D e^\lambda}{1 - \frac{e^\lambda}{4}} \end{aligned}$$

für $\lambda < \log 4$. \square

Literatur

- [1] Luc Devroye, Paul Kruszewski : *A note on the Horton-Strahler number for random trees*,