

Gauss approximationsformler

Vi vill beräkna väntevärdet och variansen av en funktion g av en stokastisk variabel X , dvs $E[g(X)]$ och $V(g(X))$. Med den aningslöse statistikerns sats förutsätter beräkningen att vi känner fördelningen för X . Här följer approximationer av $E[g(X)]$ och $V(g(X))$ utnyttjandes bara $E[X]$, $V(X)$ och funktionen $g(x)$.

Taylorutveckla $g(x)$ kring en punkt m :

$$g(x) \approx g(m) + (x - m)g'(m)$$

med likhet om $g(x) = ax + b$ för konstanter a och b . Låt $m = E[X]$. Då får vi att

1. $E[g(X)] \approx E[g(m) + (X - m)g'(m)] = g(m) + (E[X] - m)g'(m) = g(m)$.
2. $V(g(X)) \approx V(g(m) + (X - m)g'(m)) = (g'(m))^2 V(X - m) = (g'(m))^2 V(X)$.

Ett varningens ord: approximationerna fungerar bäst då fördelningen är någorlunda koncentrerad till ett intervall där $g(x)$ är approximativt linjär. För generaliseringar till fler dimensioner, $V(g(X, Y))$, etc. se kurslitteraturen.

Normalfördelningen

En stokastisk variabel X sägs vara normalfördelad med parametrar m och $\sigma > 0$ om

$$f_X(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-(x-m)^2/2\sigma^2}$$

för alla x . Läs gärna beviset i boken att detta är en giltig täthet, dvs. integrerar sig till 1. Kodbe-teckning X är $N(m, \sigma)$.

Fördelningen är symmetrisk runt m så alltså är parametern m ingenting annat än väntevärdet, $E[X] = m$. Vidare så är $D(X) = \sigma$.

Sats. Låt X_1, \dots, X_n vara en sekvens av oberoende, normalfördelade stokastiska variabler, och a_1, \dots, a_n och b konstanter. Då är

$$Y = a_1 X_1 + \dots + a_n X_n + b$$

normalfördelad, Y är $N(m, \sigma)$, med väntevärde

$$m = E[Y] = E[a_1 X_1 + \dots + a_n X_n + b] = a_1 E[X_1] + \dots + a_n E[X_n] + b$$

och varians

$$\sigma^2 = V(Y) = a_1^2 V(X_1) + \dots + a_n^2 V(X_n).$$

Alltså,

$$Y \text{ är } N\left(a_1 E[X_1] + \dots + a_n E[X_n] + b, \sqrt{a_1^2 V(X_1) + \dots + a_n^2 V(X_n)}\right)$$

och linjärkombinationer av oberoende normalfördelade stokastiska variabler är normalfördelade med rätt väntevärde och rätt varians.

Om X är $N(m, \sigma)$ så har

$$Z = \frac{X - m}{\sigma}$$

väntevärde $E[Z] = E\left[\frac{X-m}{\sigma}\right] = \frac{1}{\sigma}(E[X] - m) = 0$ och varians $V(Z) = \frac{1}{\sigma^2}V(X) = 1$. Satsen säger att Z är normalfördelad och

$$f_Z(x) = \frac{1}{\sqrt{2\pi}}e^{-x^2/2} = \varphi(x).$$

En normalfördelad s.v. med väntevärde 0 och varians (standardavvikelse) 1 sägs vara *standardnormalfördelad*. Dess täthetsfunktion betecknas av Blom med $\varphi(x)$ och dess fördelningsfunktion med $\Phi(x) = P(Z \leq x)$.

Notera att

$$F_X(x) = P(X \leq x) = P\left(\frac{X-m}{\sigma} \leq \frac{x-m}{\sigma}\right) = \Phi\left(\frac{x-m}{\sigma}\right).$$

Så för att räkna ut fördelningsfunktionens värde i en punkt för en godtycklig normalfördelning översätter vi den till motsvarande punkt för en standardnormalfördelning. Funktionen Φ finns tabulerad i formelsamlingen.

I Standardnormalfördelningen betecknas α -kvantilen med λ_α , dvs $1 - \Phi(\lambda_\alpha) = \alpha$. Dessa finns tabulerade i tabellsamlingenboken. Man kan observera att

$$\Phi(-x) = 1 - \Phi(x)$$

så $\lambda_{1-\alpha} = -\lambda_\alpha$.

Sats (Centrala gränsvärdessatsen (CGS)). Låt X_1, X_2, \dots vara en sekvens av oberoende, likafördelade stokastiska variabler med väntevärde m och standardavvikelse σ . Då gäller att

$$\lim_{n \rightarrow \infty} P\left(\frac{1}{\sigma\sqrt{n}}\left(\sum_{k=1}^n X_k - nm\right) \leq x\right) = \Phi(x)$$

Man använder konvergensen för att säga att

$$\sum_{k=1}^n X_k \overset{\text{approx}}{\text{är}} N(nm, \sqrt{n}\sigma)$$

för stora värden på n , dvs summor av stokastiska variabler är approximativt normalfördelade.

Hur stort n skall vara för att approximationen skall vara bra beror på fördelningen för de stokastiska variablerna. Symmetriska fördelningar konvergerar snabbare än assymetriska.

Hypergeometrisk fördelning

Modellsituation: Av N föremål (bollar) har s en egenskap (är svarta). Välj ut n på måfå (utan återläggning och utan hänsyn till ordning) och låt X beskriva antalet utvalda med egenskapen. Då är

$$P(X = k) = \frac{\binom{s}{k}\binom{N-s}{n-k}}{\binom{N}{n}} = \frac{\binom{Np}{k}\binom{N(1-p)}{n-k}}{\binom{N}{n}}$$

med $p = s/N$ som andelen med egenskapen i populationen.

En stokastisk variabel X med täthet enligt ovan sägs vara *Hypergeometriskt fördelad*

Man kan visa att

$$E[X] = np \quad V(X) = np(1-p)\frac{N-n}{N-1}$$

Binomialfördelning

En händelse A inträffar med sannolikhet $p = P(A)$. Gör n oberoende försök och låt X beskriva antalet gånger A inträffade. Då är

$$P(X = k) = \binom{n}{k} p^k (1-p)^{n-k}, \quad k = 0, 1, \dots, n$$

och X sägs vara *Binomialfördelad*, X är $\text{Bin}(n, p)$.

Sats.

$$E[X] = np \quad V(X) = np(1-p)$$