

vagy valamely más hasonló kifejezés lesz a lehető legkisebb. Így általában *különböző* „legjobban közelítő” egyenésekhez jutunk. Annak, hogy a (12) kifejezés minimalizálása által szolgáltatott egyenest tekintjük a legjobbnak, számítástechnikai oka is vanak.) Arra a kérdésre, hogy lehet a és b értéket úgy meghatározni, hogy a (12) kifejezés minimális legyen, könnyen tudunk választolni. Tekintsük az $F(a, b)$ függvény parciális deriváltjait

$$\frac{\partial F(a, b)}{\partial a} = -2 \sum_{i=1}^n (y_i - ax_i - b) x_i$$

$$\frac{\partial F(a, b)}{\partial b} = -2 \sum_{i=1}^n (y_i - ax_i - b).$$

Mint ismeretes az $F(a, b)$ függvény szélsőértékeit a

$$(13) \quad \frac{\partial F(a, b)}{\partial a} = 0, \quad \frac{\partial F(a, b)}{\partial b} = 0$$

egyenletek megoldásával nyerhetjük. (Az, hogy az ily módon kapott a és b értékek tényleg az $F(a, b)$ függvény minimumhelyét szolgáltatják, természetesen be kell bizonyítanunk. A bizonyítás az analízisben szerzett ismereteink alapján igen könnyű, ezért itt nem részletezzük.)

$$\text{Ebből} \quad b = \frac{50}{\sum_{i=1}^n y_i - a \sum_{i=1}^n x_i},$$

mely értéket az első egyenletbe helyettesítve kapjuk, hogy

$$\sum_{i=1}^n x_i y_i - a \sum_{i=1}^n x_i^2 - \frac{1}{50} \sum_{i=1}^n x_i \left(\sum_{j=1}^n y_j + \frac{50}{a} \right) \left(\sum_{j=1}^n x_j \right)^2 = 0,$$

$$a = \frac{\sum_{i=1}^n x_i y_i - \frac{1}{50} \sum_{i=1}^n x_i \left(\sum_{j=1}^n y_j + \frac{50}{a} \right) \left(\sum_{j=1}^n x_j \right)^2}{\sum_{i=1}^n x_i^2 - \frac{1}{50} \sum_{i=1}^n x_i^2}.$$

Mivel az előző pontban már kiszámítottuk a

$$\sum_{i=1}^n x_i, \quad \sum_{i=1}^n y_i, \quad \sum_{i=1}^n x_i y_i, \quad \sum_{i=1}^n x_i^2$$

mennyiségeket, most könnyen adódik, hogy

$$a = \frac{24\,744 - \frac{1}{50} \cdot 1100 \cdot 1119}{24\,366 - \frac{1}{50} (1100)^2} = \frac{126}{166} = 0,76,$$

15.5.2.1 A regresszióanalízis feladat típusai

A regresszióanalízis feladata két mennyiség közötti kapcsolat jellemzése egy függvény segítségével. A két mennyiség jellegétől és a kapcsolatot leíró függvény típusától függően osztályozhatjuk a feladatokat.

(i) Két valószínűségi változó közötti kapcsolat

$$b = \frac{1119 - 0,76 \cdot 1100}{283} = \frac{50}{283} = 5,66.$$

Tehát a legjobban közelítő egyenes egyenlete

$$y = 0,76x + 5,66.$$

15.5.2.1 A regresszióanalízis feladat típusai

Két valószínűségi változó, ξ és η között bár elvileg lehetséges, hogy függvénykapcsolat áll fenn, azaz például η egyértelmű függvénye ξ -nek ($\eta = f(\xi)$), gyakorlatibb, hogy ξ értékeknek fenn, azaz például η egyértelmű függvénye ξ -nek ($\eta = f(\xi)$), gyakorlatibb, hogy ξ értékeknek ismerete még nem határozza meg egyértelműen η -t. (Vizsgálj példánkban is ez volt a helyzet.) Ekkor kérdezzhetjük, hogy η eloszlásfüggvénye vagy momentumai, pl. várható érték, miképpen függ ξ -től. Alkalmában η és ξ közötti kapcsolatot jellemezhetjük úgy, hogy megadjuk, miképpen függ η várható értéke ξ -től, azaz a kapcsolatot jellemzésére az $y = f(x) = M(\eta | \xi = x)$ feltelesen várható értéket vagy ennek egy közelítését használjuk.

A feladat jobb megvilágítása céljából nézzünk egy valószínűségsszámítási példát. Valamely gépalkatrészt egykörös öntvényekből gyártunk. Az, hogy a gyártott gépalkatrészek selejtes lesz-e vagy sem, többek között függ az öntvény tisztaságától is. Gyártmányunk selejtes lehet pl., mert az öntvénybe idegen szemcse kerül. Tegyük fel, hogy az öntvényeket 1000 kp nyersanyagból öntjük, azaz 1000 darab alkatrészt gyártunk. Jelentsé η a selejtes alkatrészek számát, és jelentsé ξ az 1000 kp nyersanyagban levő idegen szemcsek számát. Ekkor η nyil-ván „függ” ξ -től, de ξ értékének pontos ismeretében sem tudjuk η értékét pontosan megmondani. Még, tudjuk mondani azomban η eloszlásfüggvényét a ξ feltétel mellett; ugyanis — mint tudjuk — egy öntvényben levő szemcsék száma Poisson-eloszlást követ, tehát annak a valószínűsége, hogy egy öntvény selejtes lesz*

$$P(\eta = k) = \binom{1000}{k} p^k (1-p)^{1000-k}.$$

Ebből η várható értéke a $\xi = x$ feltétel mellett:

$$M(\eta | \xi = x) = 1000 \left(1 - e^{-\frac{x}{1000}} \right).$$

* Itt csak a szemnyeződés folytán fellépő selejtes darabokat vesszük figyelembe.

E példában elméleti úton kaptuk meg az $M(\eta|\xi = x)$ függvényt. Legtöbb esetben nem tudunk elégét a ξ, η valószínűségi változókra ahhoz, hogy így járassunk el, hanem a ξ, η -ra vonatkozó adatokból kell az $M(\eta|\xi = x)$ függvényt (vagy annak paramétereit) megtalálni. Tegyük fel, hogy ξ, η valószínűségi változópárra vonatkozóan n kísérletet végeztünk. Legyenek ezek eredményei $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$, és keressünk egy olyan függvényt, amelynek gráfja ezen pontokhoz közel van. A közel kifejezésen ismét azt értjük, hogy a

$$(14) \sum_{i=1}^n (y_i - f(x_i))^2$$

összeg kicsi. Ha találunk egy olyan $f(x)$ függvényt, amelyre (14) valóban elegendően kicsiny, akkor e függvényt fogjuk az $M(\eta|\xi = x)$ függvény közelítésének tekinteni, és az adatok *regressziós görbéjének* fogjuk nevezni.

Az indok arra, hogy éppen a (14) kifejezést kívánjuk minimalizálni a következő. Mint tudjuk, ha η egy tetszőleges valószínűségi változó, úgy

$$(15) M(\eta - a)^2,$$

akkor lesz a legkisebb, ha $a = M(\eta)$, azaz η várható értéket úgyis meg lehet találni, hogy a (15) kifejezést minimalizáljuk. Esetünkben, ha $f(x) = M(\eta|\xi = x)$, akkor

$$\frac{1}{n} \sum_{i=1}^n (y_i - f(x_i))^2$$

kifejezés η tapasztalati szórása (a $\xi = x$ feltétel mellett), és fordítva: azon $f(x)$ függvény, amelyre

$$\frac{1}{n} \sum_{i=1}^n (y_i - f(x_i))^2$$

kifejezés minimális lesz, az $M(\eta|\xi = x)$ feltételes várható érték becslésének tekinthető. Általában nem az összes $f(x)$ függvény közül keressük ki a (14) kifejezést minimalizáló függvényt, hanem csak egy bizonyos függvényosztály elemei közül válogatunk. Lehet, hogy tudjuk vagy sejtjük, hogy a kapcsolatot lineáris, azaz $y = ax + b$, és akkor célunk azon paraméterek megtalálása, amelyre

$$\sum_{i=1}^n (y_i - ax_i - b)^2$$

minimális. Hasonlóan lehet, hogy tudjuk vagy sejtjük, hogy a kapcsolatot kvadrátikus, azaz $y = ax^2 + bx + c$, és célunk azon a, b, c paraméterek megtalálása, amelyre a

$$\sum_{i=1}^n (y_i - ax_i^2 - bx_i - c)^2$$

összeg a lehető legkisebb lesz.

Definíció. Mivel a közelítő függvény megtalálásának alapelve az, hogy az *elérések négyzetösszegét* minimalizáljuk, a módszert a *legkisebb négyzetek módszerének* is szoktuk nevezni.

(ii) Paramétertől függő valószínűségi változó (sztochasztikus folyamat)

Valamely anyag szakítási szilárdságát vizsgálva a következő módon járhatunk el. Különböző terhelések mellett megmérjük, hogy a terhelésnek kitett minták közül hány darab szakad el. Jelentsé ξ_t azt, hogy t terhelés mellett a mintaelemek hány százaléka szakad. Ekkor ξ_t (fix t esetén) egy valószínűségi változó.

Általában arra vagyunk kíváncsiak, hogy ξ_t vagy ξ_t várható értéke, $M(\xi_t)$, hogy függ a terheléstől. Hasonló feladathoz jutunk, ha csirkék súlygyarapodását vizsgáljuk. Itt ξ_t jelentse egy véletlenszerűen kiválasztott t napos csirke súlyát. ξ_t ismét valószínűségi változó és ismét ξ_t -nek, illetve $M(\xi_t)$ -nek t -től való függését vizsgáljuk. Mindkét példában kísérletünk eredménye, a ξ_t valószínűségi változó egy t paramétertől is függ. A ξ_t egy paramétertől függő valószínűségi változót sztochasztikus folyamatnak nevezünk.

Tegyük fel, hogy ξ_t értékeit különböző $t_1, t_2, \dots, t_n$ paraméterértékek esetén határozzuk meg (általában mindegyik t_i esetén több mérést végzünk). Például $t_1, t_2, \dots, t_n$ terhelések mellett nézzük meg, hogy a mintaelemek hány százaléka szakad, vagy $t_1, t_2, \dots, t_n$ napos csibék súlyát mérjük le.

A t_i paraméterérték mellett végzett kísérletek eredményei legyenek $x_{t_1}, x_{t_2}, \dots, x_{t_n}$. Az $m(t) = M(\xi_t)$ függvényt — a legkisebb négyzetek módszerének felhasználásával — úgy becsülhetjük meg, hogy megkeressük azon $f(t)$ függvényt, amelyre a

$$(16) \sum_{i=1}^n \sum_{k_i} (y_{ki} - f(t_i))^2$$

összeg a lehető legkisebb lesz. Természetesen most sem az összes $f(t)$ függvény közül keressük a (16) kifejezést minimalizáló függvényt, hanem előre megadunk egy függvényosztályt (pl. a lineáris vagy kvadrátikus függvények osztályát), és csak azt kérdezzük, hogy ezen függvényosztály elemei közül melyikre lesz a (16) kifejezés a lehető legkisebb.

(iii) Mérési hibák kiküszöbölése

Ismeretes, hogy egy vezető felmelegedése egyenesen arányos a vezetéken áthaladó áramerősség négyzetével. Az arányossági tényezői megkaphatjuk, ha ismét áramerősségi áramot vezetünk keresztül a vezetéken és lemérjük a felmelegedést. A nehézséget az okozza, hogy a mérések nem pontosak. A mérési hibák kiküszöbölése céljából általában úgy járunk el, hogy különböző erősségű áramok esetén lemérjük a felmelegedéseket, és ezen adatokból próbálunk az ismeretlen arányossági tényezőre következtetni. Általában a feladatot a következőképpen fogalmazhatjuk. Két mennyiség, x és y között ismert típusú függvénykapcsolat van, de nem ismerjük a függvényben szereplő egy vagy több paraméter értékét. Azaz

$$y = f(x; a_1, a_2, \dots, a_k),$$

ahol $a_1, a_2, \dots, a_k$ ismeretlen paraméterek. Kísérleti úton (méréssel) meghatározzuk a függvény értékét, y -t, bizonyos $x_1, x_2, \dots, x_n$ pontokban (e pontok között lehetnek egyenlők

$$\begin{aligned} A \sum_{i=1}^n x_i^2 + B \sum_{i=1}^n x_i y_i + C \sum_{i=1}^n x_i &= \sum_{i=1}^n z_i x_i \\ A \sum_{i=1}^n x_i y_i + B \sum_{i=1}^n y_i^2 + C \sum_{i=1}^n y_i &= \sum_{i=1}^n z_i y_i \\ A \sum_{i=1}^n x_i + B \sum_{i=1}^n y_i + C n &= \sum_{i=1}^n z_i \end{aligned}$$

egyenleteket.

Természetesen a többváltozós regressziós analízissel kapcsolatban is felvehetjük az egyváltozós esetben vizsgált kérdéseket (sőt több újabb kérdések is vetődnek fel), de ezekre itt nem térünk ki.

16. LINEÁRIS ALGEBRA

Tegyük fel, hogy az országban valamely gépalkatrész n helyen gyártanak és m helyen használnak fel. A gyártak legyenek $A_1, A_2, \dots, A_m$, a felhasználó helyek legyenek $B_1, B_2, \dots, B_m$. Jelentsé b_j a szoban forgó alkatrészből a B_j helyen felhasználásra kerülők számát, és hasonlóan a_i jelentse a vizsgált alkatrészből az A_i gyártban gyártott mennyiséget.

Feladatunk megadni a szállítási programját (azaz megmondani, hogy melyik gyártból mennyit szállítsunk az egyes felhasználó helyekre) úgy, hogy a szállítási költség minimális legyen. Természetesen feltételezzük, hogy az A_i ponttól a B_j pontra való szállítás költséget ismerjük. Legyen ez c_{ij} egy darab alkatrész szállítási költsége A_i -ből B_j -be). * Ugyancsak feltételezzük, hogy a kérdéses gépalkatrészről a gyártásra és felhasználásra kerülők száma megegyezik.

Ha x_{ij} jelenti az i -edik gyártból a j -edik felhasználó helyre szállított mennyiséget, akkor feladatunk már tiszta matematikai formában a következőképpen fogalmazható. Keressük azon x_{ij} ($i = 1, 2, \dots, m; j = 1, 2, \dots, m$) mennyiségeket, amelyekre

$$\begin{aligned} (1) \quad x_{ij} &\geq 0 & (i = 1, 2, \dots, m; j = 1, 2, \dots, m), \\ (2) \quad \sum_{j=1}^m x_{ij} &= b_j & (i = 1, 2, \dots, m), \\ (3) \quad \sum_{i=1}^m x_{ij} &= a_i & (j = 1, 2, \dots, m), \end{aligned}$$

és a

$$(4) \quad \sum_{i=1}^m \sum_{j=1}^m c_{ij} x_{ij}$$

összeg a lehető legkisebb. Feltesszük, hogy a_i, b_j, c_{ij} nemnegatív mennyiségek, és hogy

$$(5) \quad \sum_{i=1}^m a_i = \sum_{j=1}^m b_j.$$

* Természetesen azt is feltételezzük, hogy a szállítási költség a darabszámmal arányosan nő, azaz k darab alkatrész szállítási költsége kc_{ij} .

TÁBLÁZATOK

1. táblázat
A. táblázat
B. táblázat
C. táblázat

1. táblázat
A. táblázat
B. táblázat
C. táblázat

1. táblázat
A. táblázat
B. táblázat
C. táblázat

