

Egy új módszer állapotfüggő karbantartás kockázatalapú előrejelzésére

KOSZTYÁN ZSOLT TIBOR¹, HEGEDŰS CSABA²

Kivonat

Minden mérés bizonytalansággal terhelt, ezért a mérési eredményekre alapozott döntések hibásak lehetnek. Különösen súlyos lehet a mérési bizonytalanság következménye karbantartási döntések esetében, ahol egy berendezés meghibásodása a teljes termelési vagy szolgáltatási folyamatot leállíthatja, vagy személyi sérüléseket okozhat.

Létrehoztunk egy új modellt mérési bizonytalanság kezelésére. Modellünkben úgy módosítjuk a beavatkozási határokat, hogy a döntés első és másodfajú hibájához kapcsolódó veszteségek összege, az állapotfüggő karbantartás összes kockázata minimális legyen. Ez a módosított határ adott mérési bizonytalansághoz, folyamatingadozáshoz és a döntés adott költségszerkezetéhez tartozik. A karbantartási költségek azonban változnak az idő előrehaladtával, ezért bemutatunk egy szimulációs eljárást és egy analitikus számítást, amelyekkel minden időpillanatra meghatározható a módosított beavatkozási határ értéke. Ezt az időtől függő határt figyelembe véve idősorként kezeljük a mérési eredményeket. Így módszerünkkel megadható, hogy mikor kell a következő mintavételt elvégezni, illetve mikor kell beavatkozni egy rögzített megbízhatósági szint mellett, hogy minimálisak legyenek a költségeink.

1. Bevezetés

Minden mérés bizonytalansággal terhelt, mely bizonytalanság meghatározása szükséges a mérési eredmények pontos megadásához (BIPM, 1995). A GUM – Guide to the Expression of Uncertainty in Measurement – (BIPM, 1995) ennek a bizonytalanságnak az egységes megadásához ajánl módszereket. Azonban a GUM arra nem ad javaslatot, hogy adott bizonytalanság mellett hogyan döntsünk egy termék vagy folyamat megfelelőségéről. A GUM-ot követően megjelentek olyan tanulmányok, amelyek ezzel a kérdéskörrel foglalkoznak. Forbes (2006) Bayes-döntésként közelítette meg a megfelelőség vizsgálatot, ahol figyelembe veszi a hibás döntések költségét. Pendrill (2006) hangsúlyozta, hogy a

¹ egyetemi docens, Pannon Egyetem, Szervezési és Vezetési Tanszék, kzst@gtk.uni-pannon.hu

² PhD hallgató, Pannon Egyetem, Szervezési és Vezetési Tanszék, hegeduscs@gtk.uni-pannon.hu

döntési hibák elfogadható arányának megadásakor a döntések kockázatát kell szem előtt tartani. A kockázatok megfelelő számításához pedig a mérési bizonytalanságot csak valószínűségi eloszlásként kezelve lehet megfelelően figyelembe venni (Rossi–Crenna, 2006). Az eddigi kutatások alapján bizonytalanság figyelembe vétele hasznos a mérésekre alapuló döntések során (Forbes, 2006; Pendrill, 2006; Rossi–Crenna, 2006; Kosztyán et al., 2008), nem csak abban az esetben, ahol nagy a mérési bizonytalanság (Kosztyán–Schanda, 2006; Pajula–Ritala, 2006), hanem ott is ahol a hibás döntés nagy veszteségekkel jár (Arunraj–Maiti, 2009). Ez különösen igaz a karbantartás területére, ahol egy-egy berendezés meghibásodása a teljes termelés vagy szolgáltatás leállítását eredményezheti (Arunraj–Maiti, 2009; Krishnasamy et al., 2005).

A mérési bizonytalanság figyelembevételével foglalkozó elméletek (Forbes, 2006; Pendrill 2006; Rossi–Crenna, 2006) csak költségekkel számolnak azok minimalizálására törekednek, a vevő és a termelő kockázatát állítják egymással szembe. Korábbi tanulmányunkban már bemutattuk (Kosztyán et al., 2010), hogy a döntésektől függően realizált vagy elvesztett bevételek figyelembevételével a két nézőpont egyesíthető, a termelő szempontjából profitmaximalizáló döntés hozható.

A preventív karbantartásnál a mért értékekből a jövőre akarunk következtetéseket levonni: mi lesz a következő időszakban az állapotjellemező értéke, mikor következhet be a meghibásodás. Erre azonban, a hagyományos megfelelőségi értékelések nem alkalmasak. Ha kihasználjuk, hogy a mért értékek nem függetlenek a korábban mértektől, idősorok alkalmazásával lehetséges a jövőbeni értékek predikciója (Kosztyán et al., 2009). Az idősoroknál viszont nem számolnak a mérési bizonytalansággal (Pintelton–Schoukens, 2006) vagy azt nem választják külön a folyamat véletlen ingadozásától, a zaj részeként kezelik.

2. Elméleti áttekintés

A GUM-ban leírt módszer alapján a mérési bizonytalanság kétféleképpen jellemezhető: Eloszlásként a szórás nagyságával kifejezve (standard uncertainty). Ha több tényezőtől adódik a bizonytalanság eloszlása, akkor eredő standard bizonytalanságnak (combined standard uncertainty) nevezzük. Megadható intervallumként, mely intervallum hosszát az eredő standard bizonytalanság és egy k kiterjesztési tényező szorzataként kapjuk. A k nagyságát a megbízhatósági szint megválasztása és az eloszlásfüggvény típusa határozza meg, de gyakran 2-nek vagy 3-nak választják meg (BIPM, 1995; Rossi–Crenna, 2006). Ez

megközelítés szimmetrikusnak feltételezi az eloszlást, ami nem minden esetben áll fenn. Ezért mi k átfedési tényező helyett egy k_{LSL} alsó és egy k_{USL} felső értéket használtunk (Kosztján et al., 2008) mely értékek már nem a megbízhatóság, hanem a döntések kockázata alapján határozódtak meg (1. ábra). Így, tulajdonképpen a mérési pontok helyett intervallumot vizsgálunk a határok között, ami ekvivalens megoldás azzal, hogy ezekkel az intervallumokkal szűkítjük a határokat. Mivel az eltolások nem csak a szórástól függenek, hanem a bizonytalanság eloszlásának típusától és a döntési hibák következményétől is a szorzat alak helyett csak a határ teljes módosítását megadó K_{LSL} és K_{USL} korrekciós tényezőket használjuk a későbbiekben.

Ide kérném az 1. ábrát.

1 ábra: Megfelelőség értékelése, ha a mérési pontok helyett intervallumokat alkalmazunk (bal oldal), illetve az ezzel ekvivalens megoldás, a határok módosítása az intervallumok nagyságával (jobb oldal)

A vizsgált jellemző lefutását többféleképpen is kezelhetjük. Tekinthetjük úgy, hogy különböző állapotai vannak, melyeket mesterséges neurális hálók segítségével azonosíthatunk (Chen et al., 2007; Åkesson–Toivonen, 2006). Egy hosszabb kezdeti megfigyelés után összegyűjthető, hogy egy adott folyamatnak milyen állapotai vannak és ezek között mekkora az átmenetek valószínűsége. Azaz megkaphatjuk, hogy a mért jellemzők alapján most melyik állapotban van a folyamat és várhatóan meddig marad ebben az állapotában, majd pedig mi a legvalószínűbb állapot, amibe átvált. Ha a karakterisztika jelenlegi vagy legvalószínűbb következő állapota olyan, hogy az veszélyezteti az üzemszerű működést, be kell avatkozni.

Másik lehetőség, hogy idősróként kezeljük ezeket az értékeket, és idő- vagy frekvenciatartományban vizsgáljuk őket. Stacioner vagy stacionerré alakítható (kvázistacioner) folyamatokat kezelhetjük lineáris idősróként, melyeknél a leggyakoribb az autoregresszív integrált mozgóátlag (ARIMA) modell alkalmazása (Pintelon–Schoukens, 2006). Ezt a modellt ötvöztük a mérési bizonytalanság kezelésével.

Az ARIMA modell, a differenciaképzéssel stacionáriussá transzformált, ún. d -ed rendű integrált $[I(d)]$ idősrókra felírt ARMA modell. Az AR az autoregresszív, az MA a mozgóátlag jelzőre, az I betű (integrated) pedig az összegzésre utal. Az autoregresszív (AR) modell, az idősró jelenlegi értékét, saját előző értékeinek függvényében fejezi ki, kiegészülve a véletlen ingadozást reprezentáló változóval. A p az AR folyamat rendjét jelöli. A mozgóátlag (MA) modell az idősró jelenlegi értékét, a jelenlegi és a múltbeli véletlen

változók függvényében fejezi ki. q az MA folyamat rendjét jelöli. Az ARMA(p,q) az (1) és (2) egyenletekkel írható fel.

$$A(p^{-1})y(k) = C(q^{-1})e(k) \quad (1)$$

$$a_0y(k) + a_1y(k-1) + \dots + a_p y(k-p) = c_0e(k) + c_1e(k-1) + \dots + c_q e(k-q) \quad (2)$$

A modellazonosításhoz az autokorrelációs (ACF) és a parciális autokorrelációs (PACF) függvényeket használjuk. A MA(q) esetén az ACF a q -edik tag után eltűnik a PACF lecseng, az AR(p) esetében pedig az ACF lecseng és a PACF értékei tűnnek el a p -edik tag után.

3. Alkalmazott módszerek

Szimulációs és analitikus módszerekkel is meghatároztuk, hogy ismert mérési bizonytalanság esetén hogyan módosítsuk az elfogadási/beavatkozási határokat hogy a döntés kockázata minimális legyen. Majd a modellünket kibővítettük az idősorok kezelésével, hogy a jövőbeli értékeket, így a várható meghibásodás idejét és kockázatát előre jelezhessük.

3.1. A kockázat minimalizálása a mérési bizonytalanság figyelembe vételével

Feltételezzük, hogy ismert az x vizsgált jellemző tényleges értékének eloszlása (az eloszlás típusa és paraméterei) a korábbi mérésekből, és az m mérési hiba eloszlása, a mérőműszer kalibrálási jegyzőkönyvéből. A folyamat, berendezés, vagy termék megfelelőségéről a kettő összegeként megjelenő $y=x+m$ mért érték alapján döntünk. Akkor tekintjük megfelelőnek folyamatot, ha a vizsgált jellemző egy alsó LSL és felső USL specifikációs határ közé esik, $LSL \leq y \leq USL$. Abban az esetben, ha csak egyoldali specifikációs határunk van, akkor a fölösleges határ elhagyható a modelltől. Ténylegesen akkor megfelelő a vizsgált jellemző, ha tényleges x értéke esik a specifikációs határok közé, $LSL \leq x \leq USL$.

A mérési hiba miatt a négy esetet különböztetünk meg a tényleges megfelelőség és a meghozott döntés kombinációjaként (1. táblázat). Ha nincs beavatkozásra szükség, de a mért érték ennek ellenkezőjét mutatja, akkor fölöslegesen avatkozunk be, elsőfajú hibát vétünk. Ha a vizsgált jellemző valójában nemmegfelelő, de ezt a mérési hiba miatt nem vesszük észre, és elfogadjuk (nem avatkozunk be) akkor másodfajú hibát vétünk. Dönthetünk helyesen is, ha a nemmegfelelő folyamatba avatkozunk be vagy hagyjuk tovább futni a jó folyamatot.

1. táblázat: Nyereségek alakulása a döntés és a tényállapot függvényében

Ide kérném az 1. táblázatot.

A négy esetnél különbözőek lesznek a c_{ij} költségeink, melyek a mérések elvégzésétől, a termék és szolgáltatás létrehozásából és a meghozott döntés alapján végrehajtott cselekvésektől függenek. Azért, hogy az alternatívák választásakor elmaradt hasznokkal is számolni tudjunk a c_{ij} költségek mellett, az egyes esetek r_{ij} bevételeit is számba vettük. Így a bevételek és költségek különbségeként megjelenő $\pi_{ij}=r_{ij}-c_{ij}$ fajlagos nyereséggel számolunk.

Ez az általános modell néhány fogalmi változtatással alkalmazható karbantartási döntések következményeinek leírására is. Egy berendezés karbantartása esetén nem mindig értelmezhető a bevétel fogalma, így itt csak a költségekkel számolunk. A költségekben megjelenik a diagnosztizálás, beavatkozás és a meghibásodás költsége vagy a ki nem használt teljesítőképességből származó veszteség. Ez nem változtat a szimulációs modell felépítésén, csak a r_{ij} értékek lesznek nullák.

Legyen az x tényleges érték eloszlásának sűrűségfüggvénye $f(x)$, az m mérési hibáé pedig $g(m)$. Tegyük fel hogy a két eloszlás egymástól független így az együttes eloszlás a kettő szorzataként kapható. A 2. ábra bal oldalán az **Hiba! A hivatkozási forrás nem található.**ban bemutatott négy eset látható: a zöld paralelogramma a helyes elfogadás esete, az y és az x érték is a specifikációs határok között van. A piros területek ($LSL \leq y \leq USL$ és $x \leq LSL$ vagy $USL \leq x$) a másodfajú hiba eseteit fedik le, a kék részekkel pedig az elsőfajú hibát jelöltük. A negyedik eset a színezetlenül maradt területekhez tartozó helyes beavatkozás esete.

Ide kérném a 2.ábrát.

2. ábra: A döntések kimenetelének 4 esete (bal oldalon) és a határok módosítása által érintett területek (jobb oldalon)

Az elfogadási/beavatkozási döntéseket kell módosítani, hogy a profitot változtassuk. Az egyszerűség kedvéért legyen $K_{LSL}=K_{USL}=K$, azaz az alsó és felső határt azonos mértékben módosítjuk. Ha az egyes esetekhez tartozó profitokat súlyozzuk az esetek bekövetkezési valószínűségével, a profitmaximalizáló célfüggvény az alábbi módon írható fel:

$$\Pi(K) = \Pi(0) + \Delta\Pi(K) \rightarrow \max \quad (3)$$

A $\Pi(0)$ a korrekció nélküli ($K=0$) várható profit, $\Delta\Pi(K)$ pedig a K -tól függő változás ebben a várható profitban. Itt tulajdonképpen egy kockázat jellegű értéket kapunk, hiszen

valószínűséget szorzunk a következmény pénzben kifejezett értékével, de a kockázat negatív kicsengése miatt a várható profit elnevezést használjuk. A várható profit maximalizáláshoz elegendő a $\Delta\Pi(K)$ maximalizálása, mely a következőképpen néz ki:

$$\begin{aligned} \Delta\Pi(k) = & (\pi_{00} - \pi_{01}) \int_{-\infty}^{LSL} \left[\int_{LSL-x}^{LSL+K-x} f(x)g(m)dm + \int_{USL-K-x}^{USL-x} f(x)g(m)dm \right] dx + \\ & + (\pi_{10} - \pi_{11}) \int_{LSL}^{USL} \left[\int_{LSL-x}^{LSL+K-x} f(x)g(m)dm + \int_{USL-K-x}^{USL-x} f(x)g(m)dm \right] dx + \\ & + (\pi_{00} - \pi_{01}) \int_{USL}^{\infty} \left[\int_{LSL-x}^{LSL+K-x} f(x)g(m)dm + \int_{USL-K-x}^{USL-x} f(x)g(m)dm \right] dx \rightarrow \max \end{aligned} \quad (4)$$

Azoknál a berendezéseknél ahol kopás, degradáció lép fel és a vizsgált karakterisztika eltolódik, elegendő azt a specifikációs határt figyelembe venni, amelyik felé az eltolódott folyamat tart. Illetve előfordulhat, hogy a csak egy minimum vagy maximum értéket írnak elő, amit nem léphet át a folyamatjellemző, ekkor értelemszerűen csak ezt az egy határt kell figyelembe venni a döntés során. Csak alsó határ létezése esetén az általunk vizsgált tartományok az ábrán látható módon változnak (3. ábra).

Ide kérném az 3. ábrát.

3. ábra: A $\Delta\Pi(K)$ által érintett területek ha csak egy alsó előírt határ van

Az $y=LSL+K$ egyenes fölött elhelyezkedő pontok mind az elfogadási tartományba tartoznak, de csak az $x=LSL$ függőleges egyenestől jobbra eső pontok a ténylegesen megfelelőek. Ugyanígy az $y=LSL+K$ egyenes alatti pontok esetében elvégezzük a karbantartást, de csak a $x<LSL$ esetben volna ez szükséges. A profitváltozás egyenlete az alábbi módon fog kinézni:

$$\begin{aligned} \Delta\Pi(k) = & (\pi_{00} - \pi_{01}) \int_{-\infty}^{LSL} \int_{LSL-x}^{LSL+K-x} f(x)g(m)dmdx + \\ & + (\pi_{10} - \pi_{11}) \int_{LSL}^{\infty} \int_{LSL-x}^{LSL+K-x} f(x)g(m)dmdx \rightarrow \max \end{aligned} \quad (5)$$

3.2. Előrejelzés

Preventív karbantartási feladatokban a meghibásodás előrejelezése és megakadályozása a cél. A felügyeleti költségek és kockázatok közötti optimális arány megteremtéséhez a mintavételezési tervet kell módosítani. Korábban (Kovács et al., 2009) már bemutattunk egy

heurisztikus módszert a mérési időpontok meghatározására, ahol lineárisan közelítettük a folyamatot. Az utolsó két minta átlagára fektetett egyenessel közelítettük a csökkenés trendjét és jeleztük előre a várható meghibásodást. A következő mérés, mintavételezés ideje tulajdonképpen csak a beavatkozási határtól mért távolság és a felügyeletet ellátó szakember tapasztalatától függött. A most bemutatandó modellel megbízhatósági szintek szerint megadható a várható meghibásodás ideje és ez alapján a következő mérés időpontja. Illetve adott időpontban megadható a meghibásodás valószínűsége.

Ha kopás, degradáció lép fel a berendezésnél, akkor az ehhez tartozó karakterisztika lefutása valamilyen trendet mutat, célszerű azt idősorosan vizsgálni. Ahhoz hogy lineáris sztochasztikus folyamatmodellekkel kezelni tudjuk, dekomponálni kell a karakterisztika értékeinek idősorát. A trend adja meg a várható értéket az előrejelzésünkben. Ehhez az előrejelzéshez kapcsolódó bizonytalanságot pedig a véletlen ingadozás értékéből, a mintavételezési gyakoriságból, mintanagyságból és az előrejelzés időtávjából kapjuk meg. Ha azonos időközönként veszünk mintát, akkor a trend körüli konfidencia intervallum állandó szélességű lesz. Az intervallum alsó és felső határa párhuzamosan fut a trend alatt illetve felett. (4. ábra).

Ide kérném a 4. ábrát.

4. ábra: A mért értékekhez tartozó konfidencia intervallum

Azonos megbízhatóság mellett csökkenthető a konfidencia intervallum szélessége, ha az LSL-hez közeledve gyakrabban veszünk mintát (5. ábra), mert ekkor a mintából egyre kevesebb sokasági elemre következtetünk. A konfidencia intervallum nagysága:

$$INT_{1-\alpha} = \bar{y} \pm t_{1-\alpha/2} \cdot \frac{\sigma}{\sqrt{n}} \cdot \sqrt{1 - \frac{n}{N}} \quad (6)$$

ahol n a minta nagysága, N a sokaság, amire a mintából következtetünk, σ az összes bizonytalanság szórásként kifejezve, t pedig az $1-\alpha/2$ konfidencia szinthez tartozó Student-eloszlás értéke.

Ide kérném az 5. ábrát.

5. ábra: A mintavételezési frekvencia növelésével csökkenthető a konfidencia intervallum

A dekomponálás után identifikáljuk a valós folyamatra legjobban illeszkedő sztochasztikus folyamatot, majd meghatározzuk a paramétereit. A validálás után pedig, ha megfelelően írja le a modell a folyamatot, előrejelzésre használhatjuk a modellt. A modell a korábbi értékek alapján következtet a következőkre, ezért minél távolabbra próbálunk előrejelezni, annál nagyobb lesz a bizonytalanság (6. ábra).

Ide kérném a 6. ábrát.

6. ábra: Az előrejelzés bizonytalansága nő az előrejelzés időtávjával

A 3.1 és 3.2-es fejezetben bemutatott módon szimulációval meghatározhatjuk vagy kiszámíthatjuk legkisebb kockázattal járó beavatkozási határt, ami az idő előrehaladtával változik. Kezdetben a mérési bizonytalanságból adódó másodfajú hiba kockázata kicsi, hiszen a vizsgált karakterisztika messze esik a tényleges meghibásodást okozó határértéktől, de az kopás miatt az idő előrehaladtával növekszik. Mivel a másodfajú hiba vesztesége nagyobb, mint az elsőfajú hiba vesztesége, (hiszen csak ekkor érdemes preventív karbantartást alkalmazni,) ez a növekedés gyorsabb lesz, mint az első fajú hiba kockázatának növekedése. Ezért a minimális összes kockázat görbéje növekedni fog (6. ábra).

Ahol az előrejelzés konfidencia intervalluma metszi a minimális kockázat görbét (t_{M1}), ott kell elvégezni a következő mérést. Addig a pontig adott megbízhatóság mellett nem fog meghibásodni a berendezés. Az új mérési eredmény birtokában újra elvégezzük a dekomponálást, identifikálást és paraméterbecslést, majd ismét előrejelzünk. Addig a t_{Mi} időpontig folytatjuk ezt az iterációt, amíg a következő ($i+1$ -edik) mintavételezés és mérés költsége meg nem haladja azt a nyereséget, amit a berendezés működtetése eredményezne az i -edik és $i+1$ -edik mintavételezés között. Ekkor a t_{Mi+1} időpontban már nem mérünk, hanem karbantartást végzünk.

Ide kérném a 7. ábrát.

7. ábra: Az előrejelzés konfidencia intervallumának és a minimális kockázat görbéjének metszete határozza meg a mérések időpontját

4. Eredmények

Elvégeztük a szimulációt és a számításokat különböző eloszlástípusokra: egyenletes, háromszög és normális eloszlás (2. táblázat). Az egyenletes eloszlásnál két paramétert adtunk meg, azt a két értéket, amik között azonos valószínűséggel vesz fel minden értéket és e tartományon kívül nem vesz fel értéket a folyamatjellemző illetve a mérési hiba. A háromszög eloszlásnál az első és a második paraméter között lineárisan növekszik nulláról az értékek valószínűsége, majd pedig lineárisan csökken nullára a harmadik paraméter értékének eléréséig. Normális eloszlásnál az első paraméter az eloszláshoz tartozó várható érték a második pedig a szórás.

Példánkban csak egy alsó előírt határt adtunk meg a folyamatjellemzőre, LSL=52. Költségek szempontjából két esetet vizsgáltunk amikor jelentősen nagyobb, 15-szöröse, a másodfajú hiba vesztesége – $(\pi_{01} - \pi_{00})$ különbség – az elsőfajú hiba veszteségének – $(\pi_{10} - \pi_{11})$ különbségnek –, illetve ahol ez az arány csak 2. Ha az arány 1 vagy az alatti lenne, akkor nem érdemes preventív karbantartást végezni, az eseti volna kifizetődő. A K_{opt}^{sim} a szimulációval meghatározott optimális korrekciós tényező értéke. A $C_{sim}(K_{opt}^{sim})$ az ebben a K_{opt}^{sim} pontban szimulációval meghatározott összes költség. A K_{opt}^{calc} az analitikus számítással kapott optimális K és $C_{calc}(K_{opt}^{calc})$ az ebben a pontban számított minimális költség.

$$c_{sim}(K_{opt}^{sim}) = \frac{C_{sim}(K_{opt}^{sim})}{C_{sim}(0)} \cdot 100 \quad (7)$$

$$c_{calc}(K_{opt}^{calc}) = \frac{C_{calc}(K_{opt}^{calc})}{C_{calc}(0)} \cdot 100 \quad (8)$$

A c_{sim} és a c_{calc} a százalékban számolt költségek, ahol a 100%-ot a $K=0$ pontban (a bizonytalanság figyelembe vétele nélkül) kapott költség jelenti.

2. táblázat: A szimulációk és analitikus számítások eredményei

Ide kérném a 2. táblázatot.

Tekintsünk egy szimulációt, ahol mind a tényleges folyamat, mind a mérési bizonytalanság normális eloszlású. A tényleges folyamat várható értéke $m_x=60$ és szórása $\sigma_x=4,0825$, a

mérési hiba várható értéke $m_m=0$, szórása σ_m (a szimuláció során folyamatosan változik). A szimuláció meghatározza a döntési hibák veszteség-arányának és a mérési bizonytalanság szórásának függvényében az optimális K értéket és az ahhoz tartozó várható összköltséget. A költséget azonban nem abszolút értékével jeleníti meg, hanem arányosítja azt az ugyanolyan veszteség-arány és mérési bizonytalanság paraméterekkel rendelkező folyamat várható összköltségével, ha a K értéke nulla, azaz nem vesszük figyelembe a mérési bizonytalanságot. Tehát azt láthatjuk az ábrán, hogy adott mérési bizonytalansággal és költségszerkezettel rendelkező folyamatunk esetén mekkora az a költségcsökkenés, amit a mérési bizonytalanság figyelembe vételével elérhetünk. Minél nagyobb az arány a másod- és az elsőfajú hiba vesztesége között, annál nagyobb költségcsökkenés érhető el a mérési bizonytalanság figyelembe vételével. A 8. ábra azt mutatja, hogyan alakul a mérési bizonytalanság figyelmen kívül hagyásához viszonyított költség a mérési bizonytalanság szórása (σ_m) és a döntési hibák veszteség-arányának függvényében. Látható, hogy ha a veszteség-arány növekszik, a mérési bizonytalanság figyelembe vételével a költségmegtakarítás is növelhető. Szintén megfigyelhető, hogy a mérési bizonytalanság növekedésével a bizonytalanság figyelembe vétele egyre nagyobb költségmegtakarítást okoz. Tehát igazolódott, hogy nem csak akkor érdemes figyelembe venni a mérési bizonytalanságot, ha az nagy, hanem akkor is, ha a hibás döntések (jelen esetben a másodfajú hiba) következményeinek költsége magas.

Ide kérném a 8. ábrát.

8. ábra: Az összes költség alakulása a mérési bizonytalanság szórása és a döntési hibák veszteség-arányának függvényében

Az előrejelzésnél szimulációval meghatároztuk a mérési bizonytalansággal kapcsolatos minimális összes kockázatot jelentő görbét, mint beavatkozási határt. A kezdeti mért adatokból megkaptuk hogy egy trendre és véletlen ingadozásra lehet felbontani az idősort. A trend egy exponenciális csökkenésű görbe. Az y_T a t -edik időpontban mért érték lenne, ha csak véletlen ingadozás mentes trend lenne a folyamat.

$$y_T = 2810 - 233.58 \cdot \exp(0.0021 \cdot t) \quad (9)$$

A véletlen ingadozást legjobban leíró sztochasztikus folyamat az identifikálás után az ARIMA(1,1,1) folyamat. A modell paraméterei a 3. táblázatban láthatóak.

3. táblázat: Az ARIMA modell paraméterei

Ide kérném a 3. táblázatot

A t_M időpontban éri el az előrejelzés konfidencia intervalluma a minimális összes kockázat szintjét, ekkor kell legkésőbb elvégezni a következő mérést. Az utolsó mért pont és t_M közötti távolság 80 mérési időköznek felel meg (9. ábra).

Ide kérném a 9. ábrát.

9. ábra: A következő mérési pont mintegy 125 mintavételi időszakra van a legutóbbi méréstől

5. Összefoglalás

Ebben a tanulmányban egy új egységes modellt mutattunk be, amely együtt kezeli a termelői és vevői kockázatokat. A modell az egy illetve két megfeleléségi határral rendelkező folyamatoknál is megadja az optimális beavatkozási határt, amelynél az összes kockázat a legalacsonyabb, a preventív karbantartási döntéshez kapcsolódó várható nyereség a legmagasabb. Ha a folyamat előrejelezhető – stacioner vagy kvázistacioner –, meg tudjuk mondani, hogy mikor kell legkésőbb elvégezni a következő mérést, hogy adott megbízhatóság mellett minimalizáljuk a mérési költségeket, de ne veszélyeztessük a folyamat működését. Modellünket érdemes használni minden olyan esetben, ahol a másodfajú hiba vesztesége ($\pi_{01} - \pi_{00}$) magasabb az elsőfajú hiba veszteségénél ($\pi_{10} - \pi_{11}$). Az előrejelzéssel kibővített modell pedig akkor hoz nagyobb javulást az eredményekben, ha a mérés költsége jelentős, és nem akarunk minden időpillanatban mérni. Modellünkkel javítható az állapotfüggő karbantartás gyengesége, a nehéz a tervezhetőség.

Irodalomjegyzék


- Åkesson, B.M., Toivonen, H.T. (2006): State-dependent parameter modelling and identification of stochastic non-linear sampled-data systems. *Journal of Process Control*, pp. 877–886.
- Arunraj, N.S. and Maiti, J. (2009): A methodology for overall consequence modeling in chemical industry *Journal of Hazardous Materials* 169 pp. 556–574
- BIPM, IEC, IFCC, ISO, IUPAC, IUPAP and OIML (1995): Guide to the Expression of Uncertainty in Measurement, ISO, Geneva, 1995.

- Chen, Z., Lu, S., Lam, S. (2007): A hybrid system for SPC concurrent pattern recognition. *Advanced Engineering Informatics* 21 (2007) 303–310
- Forbes, A.B. (2006): Measurement uncertainty and optimized conformance assessment. *Measurement* 39. pp. 808-814.
- Kosztján Zs.T., Schanda J.(2006): Flatbed scanners and CCD-cameras: colorimetric characterization and uncertainties, *2nd Expert Symposium on Measurement Uncertainty*, 11–17 June, pp. 219-228
- Kosztján, Zs. T., Csizmadia, T., Hegedűs, Cs., Kovács, Z. (2009): A new approach to forecasting conformity treating measurement uncertainty in SPC, AVA (International Congress on the Aspects and Vision of Applied Economics and Informatics), Debrecen 26 March 2009.
- Kosztján, Zs. T., Csizmadia, T., Hegedűs, Cs., Kovács, Z. (2010): Treating measurement uncertainty in complete conformity control system. *Innovations and Advances in Computer Sciences and Engineering* (edited by Tarek Sobh) Springer Netherlands, 2010. pp. 79-84
- Kosztján, Zs.T., Csizmadia T., Hegedűs, Cs. (2008): Mérési bizonytalanság figyelembe vétele mintavételes megfelelőségvizsgálatnál. *XX. Nemzetközi Karbantartási Konferencia*, pp. 152-163
- Kovács, Z., Hegedűs Cs., Kosztján, Zs. T., Csizmadia, T. (2009): Bizonytalanságok figyelembe vétele műszaki diagnosztika esetén, *XXI. Nemzetközi Karbantartási Konferencia*. Veszprém, Hungary, 8-9 June 2009. pp. 159-168
- Krishnasamy, L., Khan, F., Haddara, M. (2005): Development of a risk-based maintenance (RBM) strategy for a power-generating plant. *Journal of Loss Prevention in the Process Industries* 18 pp. 69–81
- Pajula E, Ritala R. (2006): Measurement uncertainty in integrated control and process design—A case study. *Chemical Engineering and Processing*. 2006 ;45(4):312-322.
- Pendrill, L.R. (2006): Optimised measurement uncertainty and decision-making when sampling by variables or attribute *Measurement* 39. pp. 829-840.

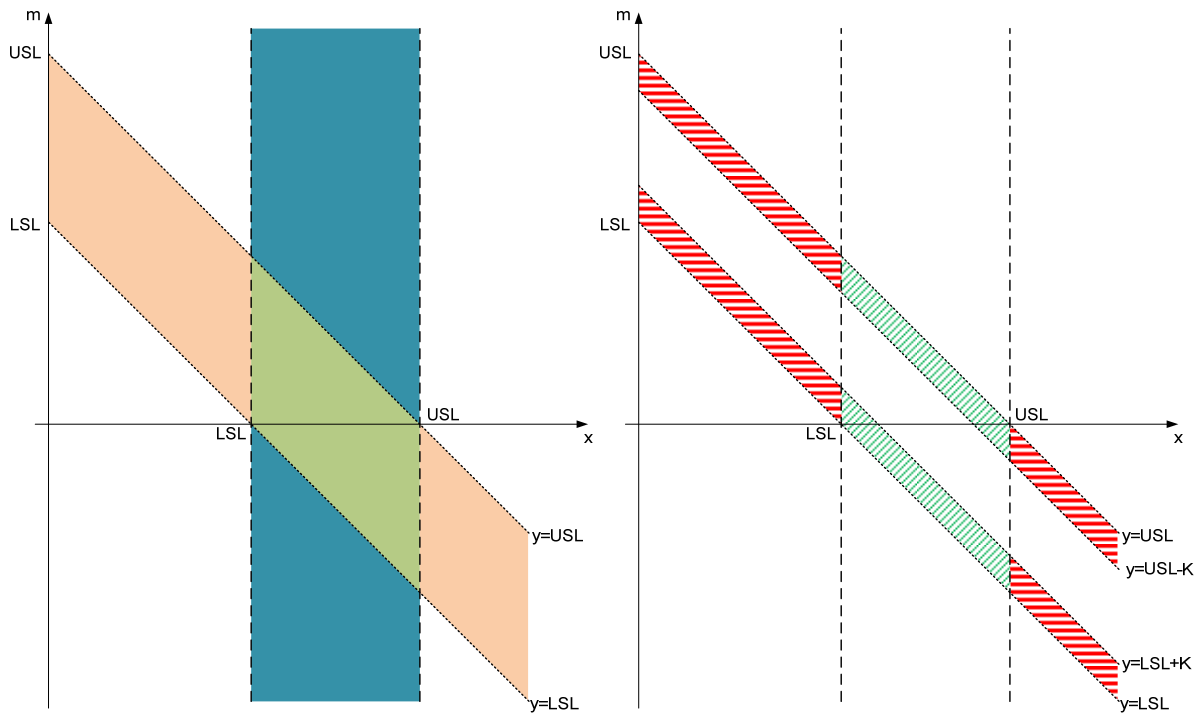
Pintelon, R., Schoukens, J. (2006): Box-Jenkins identifications revisited – Part I: Theory.
Automatica 42. pp. 63-75.

Rossi G, Crenna F. (2006): A probabilistic approach to measurement-based decisions.
Measurement 39. pp. 101-119.


Ábrák:



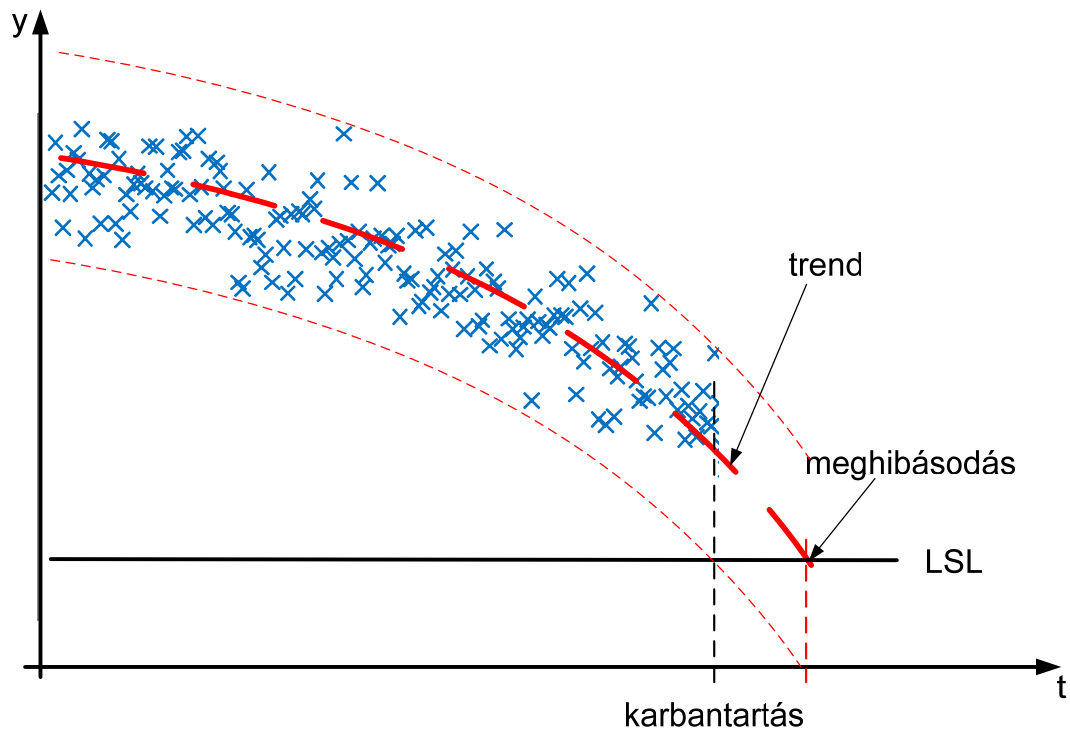
1.ábra: Megfelelés értékelése, ha a mérési pontok helyett intervallumokat alkalmazunk (bal oldal), illetve az ezzel ekvivalens megoldás, a határok módosítása az intervallumok nagyságával (jobb oldal)



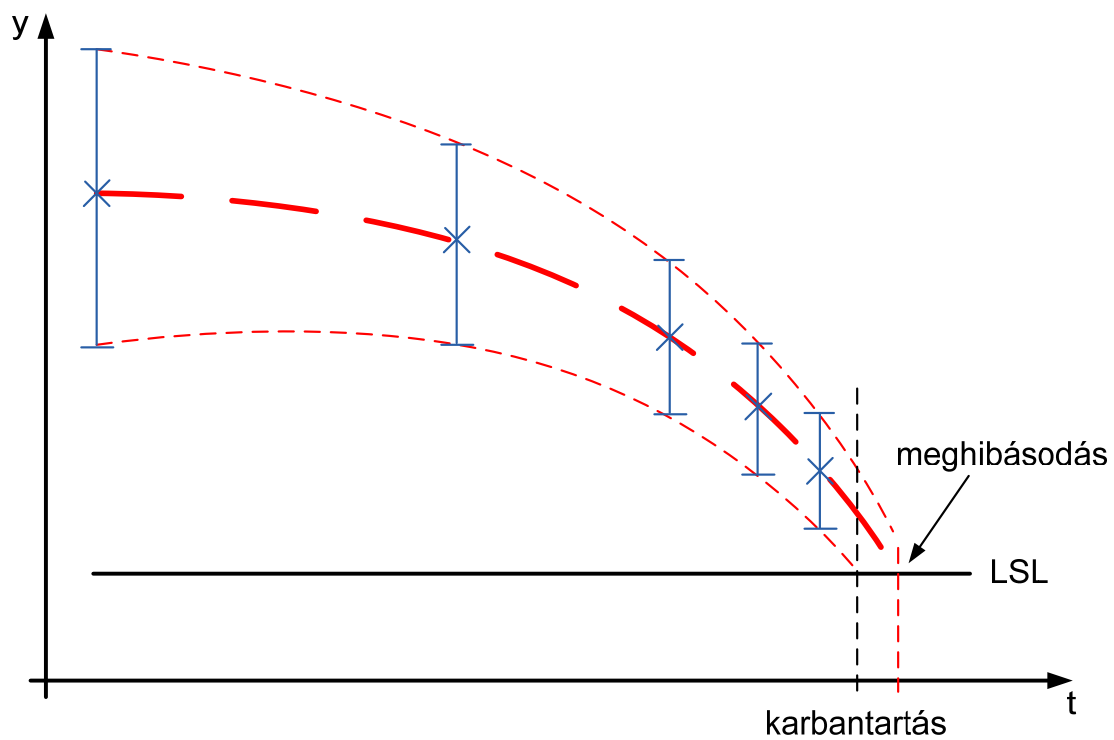
2.ábra: : A döntések kimenetelének 4 esete (bal oldalon) és a határok módosítása által érintett területek (jobb oldalon)




3. ábra: A $\Delta T(K)$ által érintett területek ha csak egy alsó előírt határ van




4. ábra: A mért értékekhez tartozó konfidencia intervallum




5.ábra: A mintavételezési frekvencia növelésével csökkenthető a konfidencia intervallum



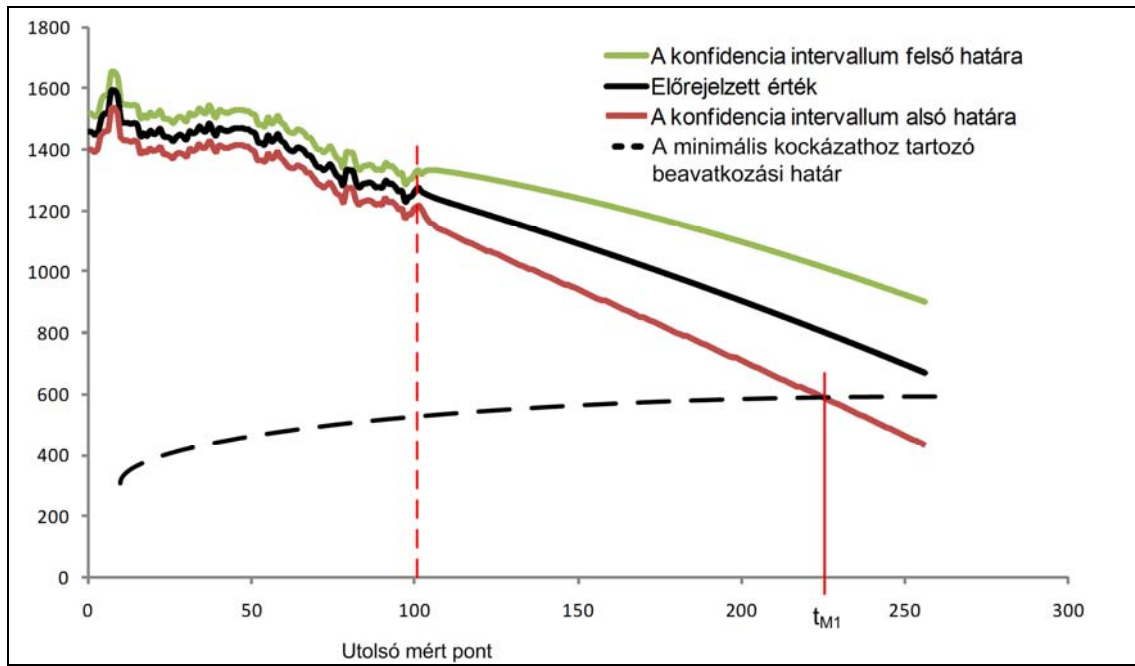
6.ábra: Az előrejelzés bizonytalansága nő az előrejelzés időtávjával



7.ábra: Az előrejelzés konfidencia intervallumának és a minimális kockázat görbéjének metszete határozza meg a mérések időpontját



8. ábra: Az összes költség alakulása a mérési bizonytalanság szórása és a döntési hibák veszteség-arányának függvényében



9.ábra: A következő mérési pont mintegy 125 mintavételi időszakra van a legutóbbi méréstől

Táblázatok:

1.táblázat:

Nyereség/Veszteség	Döntés	
	Nem végezzük el a karbantartást/beavatkozást (1)	Elvégezzük a karbantartást/beavatkozást (0)
Nem szükséges karbantartás/beavatkozás (1)	$\pi_{11}=r_{11} - c_{11}$ Helyes elfogadás	$\pi_{10}=r_{10} - c_{10}$ Felesleges beavatkozás
Tény Karbantartás/beavatkozás szükséges (0)	$\pi_{01}=r_{01} - c_{01}$ Helytelen elfogadás	$\pi_{00}=r_{00} - c_{00}$ Helyes beavatkozás

2.táblázat: A szimulációk és analitikus számítások eredményei

A tényleges értékek eloszlása	A mérési bizonytalanság eloszlása	$\frac{\pi_{01} - \pi_{00}}{\pi_{10} - \pi_{11}}$	K_{opt}^{sim}	K_{opt}^{calc}	$c_{sim}(K_{opt}^{sim})$	$c_{calc}(K_{opt}^{calc})$
egyenletes (50,70)	egyenletes (-3,3)	15	2.6250	2.6393	26.08%	26.14%
		2	0.9798	0.9986	95.93%	95.96%
háromszög (50,60,70)	egyenletes (-3,3)	15	1.9693	2.1890	68.21%	68.01%
		2	-1.6469	-1.4563	79.09%	78.39%
normál (60,4.0825)	egyenletes (-3,3)	15	1.9745	1.8341	66.34%	66.28%
		2	-1.1109	-0.9758	90.24%	89.46%
egyenletes (50,70)	háromszög (-3,0,3)	15	1.9484	1.9425	29.81%	29.81%
		2	0.4468	0.5038	93.14%	93.00%
háromszög (50,60,70)	háromszög (-3, 0,3)	15	1.3543	1.4005	58.89%	58.15%
		2	-0.3438	-0.2383	97.68%	96.55%
normál (60,4.0825)	háromszög (-3, 0,3)	15	1.3264	1.2106	57.72%	57.27%
		2	-0.1441	-0.1947	98.95%	97.19%
egyenletes	normál	15	1.8698	1.8870	32.44%	32.32%

(50,70)	(0,1.2247)	2	0.5182	0.4801	93.20%	93.19%
háromszög (50,60,70)	normál (0,1.2247)	15	1.3016	1.1185	58.79%	55.21%
		2	-0.2738	-0.3504	97.83%	97.70%
normál (60,4.0825)	normál (0,1.2247)	15	1.2436	1.2546	58.18%	58.08%
		2	-0.1438	-0.1770	99.21%	98.96%

3.táblázat: Az ARIMA modell paraméterei

Paraméterek	Becsült érték	SE	t	Szignifikancia szint
Konstans	0.043	0.302	0.141	0.888
AR Elsőrendű tag	0.682	0.043	15.994	0.000
Differencia tag rendje	1			
MA Elsőrendű tag	0.903	0.025	35.828	0.000