

MŰANYAGOK FELDOLGOZÁSA, ADDITÍV TECHNOLÓGIÁK

Fröccstermékek minőségét befolyásoló tényezők vizsgálata

A fröccsöntő szerszámok és forrócsatornás rendszerek kialakításánál a műanyagömlédek összenyomhatóságát gyakran nem kellő komolysággal veszik figyelembe, noha ez jelentős hatással van a termékek minőségére. Egy másik tényező, hogy a gépi tanulás, automatizált módon elkészíthető minőség-előrejelző modellek fejlesztése kezd reális ipari alternatívává válni.

Tárgyszavak: műanyag-feldolgozás; fröccsöntés; minőségjavítás; polisztirol; gépi tanulás.

A fröccsöntött műanyag alkatrészeket az élet szinte minden területén, és sokszor nagyon kényes alkalmazásoknál is elterjedten használják, ezért egyre nő a velük szemben támasztott minőségi követelmény. Miközben a fröccsöntő üzemek a gyártás nyereségességét és a határidők teljesítését is alapvetően fontosnak tartják, egyes alkalmazási területen versenyképességük megőrzése csak a kiváló minőség biztosításával lehetséges. A fröccstermékek minőségét számos tényező befolyásolja, az alábbiakban ezek közül mutatunk be néhányat.

A műanyagömlédek összenyomhatóságának mértéke

A fröccsöntő szerszámok és forrócsatornás rendszerek kialakításánál a műanyagömlédek összenyomhatóságát gyakran nem kellő komolysággal veszik figyelembe, noha ez jelentős hatással van a termékek minőségére. Egy adott rendszerben ugyanis ez határozza meg, hogy mennyi anyagot juttatunk be a szerszámüregbe az ömladék megdermedése előtt.

Az ömladék összenyomhatóságát általában az adott alapanyag p_{tv} (nyomás, hőmérséklet, fajtérfogat) diagramjából olvassák ki, ami azonban sokszor félrevezető értékekhez vezet. Az ömladék tényleges összenyomhatóságának különösen nagy jelentősége van a sokfészkes és a nagyméretű forrócsatorna rendszereket használó szerszámoknál.

Optimális esetben az összenyomhatóságot figyelembe veszik a fröccségység és a záróegység teljesítményének kiválasztásához is. A fröccségység méretének kiválasztásánál gyakran csak az adagsúlyt veszik figyelembe. Azonban, különösen a kis tömegű fröccstermékek, a sokfészkes szerszámok és a nagy anyagmennyiséget tartalmazó forrócsatornás rendszerek esetében, általában nagyobb fröccségységre van szükség.

A műanyagömlédek összenyomhatóságának hatását vizsgálta a fröccsöntő gépeket gyártó német Arburg cég egy munkatársa, bevonva egy szerszámtervező és egy forrócsatorna rendszereket gyártó céget is. Figyelemmel kísérte a fröccségység, a fúvóka, a forrócsatornás rendszer és a szerszámfészkek beépített érzékelőinek adatait, hogy képes legyen az elméleti számítások és a gyakorlati eredmények összehasonlítására.

Az elméleti összenyomhatósági értékek kiszámításához három, a szakirodalomban megtalálható megközelítést alkalmazott:

- a Renner megközelítést: ami 4 koefficienset tartalmaz az amorf és 7 koefficienset a részben kristályos műanyagok esetében,
- az IKV megközelítést: amelynél 13 koefficienset használnak,
- a 2-doménes Tait megközelítést: ahol szintén 13 koefficiens szerepel.

Az adott számításoknál azonban mindig ezek közül csak az egyiket, nem pedig kombinációjukat használta.

A kísérletekhez egy Arburg gyártmányú *Allrounder 470H* fröccsöntő gépet használtak, amelynek záróereje 1000 kN volt. A fröccsgép vezérlése a csiga pozíciójának mérésén alapult, fel volt szerelve hidraulikátárolóval és szervo-elektromos adagoló funkcióval. A mérésekhez nyolcfélszkes piskóta próbatest szerszámot (gyártó Polar-Form GmbH) alkalmaztak, a forrócsatornás rendszert az Otto Manner GmbH szállította. A minőségbiztosításhoz szükséges érzékelőket és programokat a Priamus System Technologies cég adta. Összesen 29 nyomás- és hőmérséklet-érzékelőt építettek be, ezek közül többet a forrócsatornás rendszerbe. A mérésekhez mind amorf, mind pedig részben kristályos műanyagokat is felhasználtak.

A vizsgálatok alapján megállapítható volt, hogy minél magasabb értékű a hőmérséklet, a nyomás és az anyag térfogata, annál nagyobb lesz az összenyomhatóság. A számított és mért értékek jó egyezést mutattak. Így például polisztirol (PS) esetében az össztérfogat $215,32 \text{ cm}^3$, a mért összenyomódás $13,98 \text{ cm}^3$ (vagyis 6,5%), a számított összenyomódás pedig $14,77 \text{ cm}^3$, tehát az eltérés mindössze 0,37% volt.

Gépi tanulás a fröccsparaméterek beállításánál

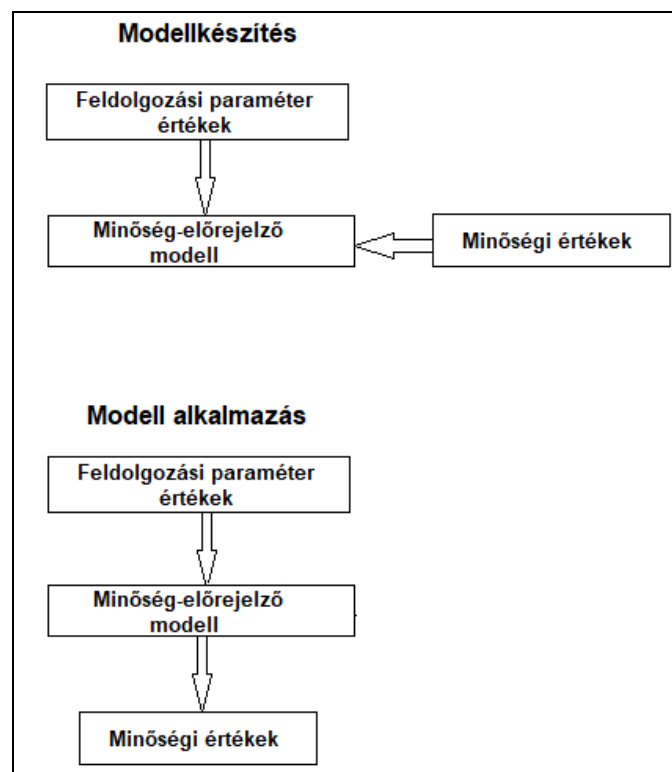
Már évek óta foglalkoztatja a fejlesztőket, hogyan lehet a feldolgozási paraméterek beérkező adatai alapján előre jelezni az adott ciklusban készített fröccstermék minőségét, illetve, hogyan lehet az ilyen adatokra alapozott gépi tanulás alkalmazásával a gépbeállítást automatizálni.

A gépi tanulás alkalmazását a fröccsöntésben, és általában a műanyag-feldolgozásban alapvetően két tényező hátráltatja. Az egyik az elkerülhetetlen tanulási fázis hossza, amely nélkül nem lehet felállítani a minőségbiztosítási modellt az adott gépre, szerszámra és termékre. A másik az alkalmazás komplexitása, azoknak a lépéseknek a nagy száma, amelyeket korábban kézi vezérléssel kellett végrehajtani.

Mivel a fröccsöntési folyamatot nagyon sok paraméter értéke befolyásolja, fontos, hogy tisztázzuk, ezek közül melyeknek van döntő befolyása a termékminőség alakulására. A német Duisburg-Essen Egyetem (Institut für Produkt Engineering – IPE) intézetének kutatói megkezdtek e problémakör feltárását. Munkájuk során szisztematikusan vizsgálták, mely paramétereket kell bevonni a minőségi prognózismodell kifejlesztéséhez a gépi tanulásnál. Ennek során megvizsgáltak és felhasználtak már korábban kifejlesztett algoritmusokat, hogy automatikusan kiválaszthatóvá tegyék, hogy milyen adatok, feldolgozási paraméterek gyakorolnak döntő hatást a tanulási algoritmusokra és végső soron a hiperoptimalizációra és modellillesztésre.

A jelen munka során a fröccsöntő szerszámüregek belsejében elhelyezett nyomásérzékelők adatainak befolyását vizsgálták a termékminőség alakulását előrejelző modellekre. Az általuk alkalmazott eljárást felügyelt tanulásnak is nevezik. Ennek során regressziót és osztályozást alkalmazhatunk. A regressziót a folyamatos változást mutató minőségi jellemzőknél (pl. a súly, méret) használhatjuk, míg az osztályozást az olyan eldöntendő jellegűeknél, mint az, hogy jelentkezik-e a darabon beszívódás, vagy sem.

A feldolgozási paraméterek aktuális értékeit (a beállított értékekkel együtt) a fröccsgép vezérlésén keresztül a beépített érzékelők jelei szolgáltatják. A feldolgozási paraméterek nem mindegyike rendelkezik szignifikáns értékkel a minőségre nézve, mivel az egyes feldolgozási paraméterek között több-kevesebb redundancia állhat fenn. Ha ezeket az irreleváns/redundáns paramétereket is beépítjük a modellünkbe, akkor túl komplex modellt kapunk, ami jóval nagyobb számítási kapacitást és hosszabb tanulási fázist igényel és végső soron gyengébb teljesítményű modellhez vezet. Ezért a modell felállításánál az első lépés a releváns, vagyis egymással nem, vagy csak nagyon kis mértékben redundáns feldolgozási paraméterek meghatározása (1. ábra).

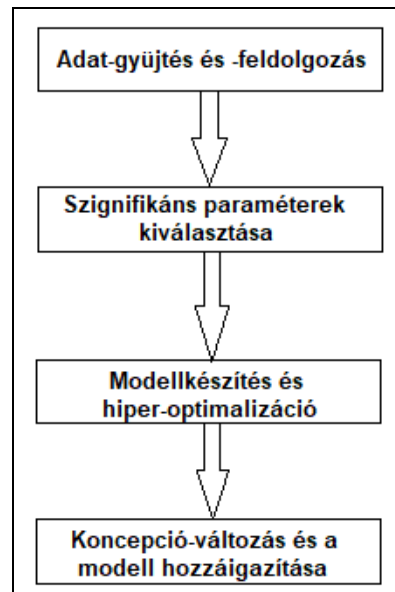


1. ábra A modell alapú minőség-előrejelzés előtt tanulási fázisra van szükség, amelynél mind a feldolgozási paraméterek értékeire, mind pedig a minőségre vonatkozó értékekre szükség van

A releváns feldolgozási paraméterek kiválasztására többféle, korábban már kifejlesztett algoritmust lehet használni, amelyek az ún. szűrő, becsomagoló, vagy pedig a beágyazó eljárással működnek a releváns paraméterek kiválasztásánál. A kis számítási kapacitást igénylő

szűrő módszer heurisztikus, míg a másik kettőnél a tanulási fázissal folyamatos kölcsönhatás és ezért nagyobb számítógép kapacitás szükséges.

A számítástechnika mai fejlettsége lehetővé tette, hogy a kutatók mindhárom módszert alkalmazhatták a hiperparaméterek meghatározásán alapuló modellkészítéshez. Ezek optimális megválasztásához a *Bayes-Optimalizációt* használták egy ötszörös kereszt-validálással, vagyis a beérkező adatok 80%-át a gépi tanulásra, 20%-át pedig a kialakuló modell validálására (érvényességének vizsgálatára) használták. E módszer részletezése meghaladja a jelen publikáció kereteit. A fenti lépések kombinációjával egy következetes adatfeldolgozási lánc (2. ábra) hozható létre, amely lehetővé teszi egy minőség-előrejelző modell teljesen automatikus létrehozását.



2. ábra A következetes adatfeldolgozás lehetővé teszi a minőség-előrejelző modell létrehozásának automatizálását

A kísérletekhez használt teljesen elektromos szervomotorokkal meghajtott fröccsöntő KraussMaffei gép típusa *PX 120-380*. A mérésekhez egy kétfészkés, legyező beömlésű szerszámot használtak, amellyel vékonyfalú négyzetes próbatesteket gyártottak *Moplen HP501H* polipropilénből (gyártó: LyondellBasell Industries N.V.). Mindkét szerszámfészekbe nyomásérzékelőt (*Unisens 6157BA*, Kistler Instrumente GmbH) építettek be, az egyik fészekbe a gát közelében a középvonalon, a másikonál az egyik szélén, az élhossz kb. 2/3-ánál. A darabok kiemeléséhez és mozgatásához egy lineáris robotot használtak. Minden egyes ciklusnál mérték a termékek súlyát egy automatikus mérlegen, majd az egy szállítószalagon haladva lehűlő termékek hosszát egy digitális kamera segítségével. A mérési adatokat megfelelő interfész segítségével juttatták el a kiértékelést végző számítógépbe.

A feldolgozási és minőségi adatok kiértékeléshez egy teljes, központi és csillagpontokat is tartalmazó faktoriális kísérletet terveztek. A vizsgált paraméterek a következők voltak:

- a befröccsöntés sebessége,
- utónyomás nagysága,
- utónyomás ideje,
- hűtési idő,
- a csigahenger hőmérséklete (fűvókánál).

Összesen 860 ciklus adatait dolgozták fel a modell létrehozásához és kiértékeléséhez. A mintegy 40 feldolgozási paraméterből azt az ötöt választották ki, amelyek kombinációja a legnagyobb relevanciát, azaz a legkisebb mértékű redundanciát adta. Ehhez a szekvenciális a *Pearson-Korrelációt* használták relevancia kritériumként (korreláció alapú jellemző szelekció (CFS)). A későbbiekben számításba vették továbbá a szerszámban elhelyezett két nyomásérzékelő adatait is.

Az öt, fentiek szerint kiválasztott, feldolgozási paramétert használták a minőség-előrejelző modell felépítéséhez, amelyet a mért adatok 80%-ának felhasználásával gépi tanulással hoztak létre. A tanuláshoz a következő 7 felügyelt tanulási módszert használták a regresszióhoz:

- többszörös lineáris regresszió,
- mesterséges ideghálózat,
- támogató-vektor módszer,
- Gauss-folyamat regresszió,
- a k-adik legközelebbi szomszéd módszer,
- bináris döntési fa módszer,
- bináris döntési fa együttes módszer.

Annak megállapításához, hogy milyen mértékben járulnak hozzá a szerszámban elhelyezett nyomásérzékelők adatai a minőség-előrejelző modell hatékonyságához, három különböző modellt hoztak létre:

1. Egy olyan modellt, amelynél csak az 5 feldolgozási paraméter adatai szerepelnek
2. Egy olyan modellt, amelynél az 5 feldolgozási paraméter adatai és a szerszámba beépített nyomásérzékelők adatai is szerepelnek
3. Egy olyan modellt, amelynél csak a szerszámba beépített nyomásérzékelők adatai szerepelnek

1. táblázat

A különböző feldolgozási paraméter értékeket használó modellek által biztosított minőség-előrejelzés megfelelése (%) a termék súlyára vonatkoztatva

A regresszió tanulási módszere	1. Modell	2. Modell	3. Modell
Többszörös lineáris regresszió	98,8	99,3	95,3
Mesterséges ideghálózat	99,2	99,0	97,7
Támogató-vektor módszer	99,5	99,5	97,0
Bináris döntési fa módszer	99,4	99,4	98,5
Bináris döntési fa együttes módszer	99,4	99,6	98,2
Gauss-folyamat regresszió	99,5	99,5	97,7
A k-adik legközelebbi szomszéd módszer	99,3	99,2	94,2

A különböző gépi tanuló minőség-előrejelző modellekkel azt kapták, hogy a csupán a szerszámfészkekben mért nyomást használó 3. Modell (>94%) kivételével, a másik két modell (1. és 2. Modell) nagyon jól (>99%) biztosította a fröccsöntött termékek súlyát (1. táblázat). Ugyanakkor a termék hosszmérete esetében a modellek megfelelése lényegesen gyengébb volt, a megfelelési érték a regressziós módszertől függően az 1. és 2. Modellek esetében 63–77% között, a 3. Modell esetében pedig 53–72% között mozgott (2. táblázat).

2. táblázat

A különböző feldolgozási paraméter értékeket használó modellek által biztosított minőség-előrejelzés megfelelési értéke (%) a termék hosszára vonatkoztatva

A regresszió tanulási módszere	1. Modell	2. Modell	3. Modell
Többszörös lineáris regresszió	74	74	68
Mesterséges ideghálózat	75	77	69
Támogató-vektor módszer	77	74	70
Bináris döntési fa módszer	74	73	67
Bináris döntési fa együttes módszer	73	76	67
Gauss-folyamat regresszió	75	76	72
A k-adik legközelebbi szomszéd módszer	63	64	53

Az eredmények elemzése azt mutatta, hogy a szerszámfészkekben mért nyomással korrigált modellek 98,3%-ban mutattak korrelációt a csak a másik 5 feldolgozási paraméterrel dolgozó modellel (vagyis redundáns paraméternek bizonyult), ezért a gépi tanulásnál nincs szükség arra, hogy ezt a paramétert is beépítsük a minőség-előrejelző modellbe.

Összeállította: Dr. Füzes László

Meder I.: Schmelzkompression praxisnah berechnen = Kunststoffe, 6. sz. 2020. p. 40–42.
 Schulze Struchtrup A, Kvaktun D., Schiffers R.: Qualitätsprognose für Spritzgussteile durch maschinelles Lernen = Kunststoffe, 6. sz. 2020. p. 36–39.