



M Ű E G Y E T E M 1 7 8 2

BUDAPESTI MŰSZAKI ÉS GAZDASÁGTUDOMÁNYI EGYETEM
GÉPÉSZMÉRNÖKI KAR
POLIMERTECHNIKA TANSZÉK

FRÖCCSÖNTÉS KITÖLTÉSI ÉS UTÓNYOMÁSI FÁZISÁNAK OPTIMALIZÁLÁSA
MEGERŐSÍTÉSES TANULÁS ALKALMAZÁSÁVAL

PHD ÉRTEKEZÉS TÉZISFÜZET

KÉSZÍTETTE:

PÁRIZS RICHÁRD DOMINIK

OKLEVELES GÉPÉSZMÉRNÖK

TÉMAVEZETŐ:

DR. TÖRÖK DÁNIEL

2025

A doktori disszertáció bírálata és a védésről készült jegyzőkönyv a
Budapesti Műszaki és Gazdaságtudományi Egyetem
Gépészmérnöki Karának Dékáni Hivatalában megtekinthető

1. Bevezetés

A 21. században egy új ipari forradalom megy végbe szépen fokozatosan, az úgy nevezett Ipar 4.0. Ennek lényege többek között az, hogy megvalósítsa a szenzorosan és egyéb módon mérhető nagy mennyiségű adatok, felhasználásával különböző gépek és szoftverek egymás közti kommunikációján alapuló szabályozást, folyamatfelügyeletet, ezáltal pedig produktívabb és kevesebb emberi beavatkozást igénylő gyártás legyen elérhető. Ez a tendencia természetesen újabb stratégiákat, módszereket igényel, amelyeket esetleg az egyes technológiákra rá kell szabni bizonyos mértékben.

Az Ipar 4.0 természetesen a polimerfeldolgozó technológiákat is eléri. Bizonyos szempontok szerint az additív gyártástechnológiák már önmagukban megújították a gyártási folyamatokat azáltal, hogy a terméket alapanyag hozzáadással hozzák létre a korábbiakban igen jellemző anyageltávolítási technológiákkal szemben (mint például a forgácsolás). Emellett természetesen az aktuális forradalom az ömledékformázási technológiákat is érinti, amiknél a forró ömledékállapotban lévő alapanyaggal egy formaüreget töltenek ki. A polimerek feldolgozásánál az egyik legjelentősebb ilyen típusú technológia a fröccsöntés, ahol a polimer alapanyagot az olvadási hőmérséklet-tartomány fölé hevítik, majd viszonylag nagy nyomással, rövid idő alatt egy temperált szerszámba fecskendezik ezt az ömledéket, hogy az az előre kialakított háromdimenziós termék alakját vegye fel.

A fröccsöntés egy relatív komplex eljárás, ahol a folyamatot általában számos szakaszra szokás osztani a szerint, hogy a sok gépi paraméter közül melyek hatása jelentős az adott részben. A technológiát a számos gépi paraméter mellett tovább bonyolítja, hogy önmagukban a polimerek szerkezete és ebből adódóan a viselkedésük is kellően komplikált. A polimerek hosszúláncú molekulákból álló szerkezetek. A molekulákat felépítő ismétlődő egységek típusa, a molekulák hossza és az egyes molekulák közti kapcsolatok nagyon sokféle lehetőséget biztosítanak a végső termék mechanikai, geometriai, vegyszerállósági és egyéb tulajdonságainak változtatására. Emiatt természetesen az egyes eltérő polimer típusok feldolgozásához más-más technológiai paraméterek szükségesek, amik a fröccsöntési technológiai optimalizálását nehezítik. Az alapanyag mellett természetesen a végső formát meghatározó szerszám geometriája ugyancsak jelentősen tudja befolyásolni a fröccsöntés kimenetelét, ugyanis az ömledék útját meghatározó csatorna, a szerszámban lévő hűtőkörök által meghatározott hőelvonási jelenségek (és még sok egyéb jellemző) jelentős hatással lehet arra, hogy egy termék a feladatát milyen mértékben képes ellátni.

Nem meglepő tehát, hogy a fröccsöntési technológia egy rendkívüli módon kutatott eljárás a folyamatoptimalizálás szempontjából. Napjainkban a fröccsöntésnél korábbiakban gyakran használt hagyományos modellezési eljárásokat (mint például lineáris modell illesztés vagy faktor analízis) egyre inkább felváltják az úgy nevezett gépi tanulási technológiák. Ennek fő oka az, hogy a technológia bonyolultsága miatt az egyes speciális kutatási esetekben leírt modellek, hatások nem tekinthetők általános jellegűnek. Ezért a kutatások inkább a különböző szenzoros adatokból képzett sokdimenziós terekben elrejtett mintázatok felismerésével, és azok kiaknázásával foglalkoznak, amely feladatokra ezek a gépi tanulási módszerek rendkívül alkalmasak.

A gépi tanulási módszerek számos modellt magukba foglalnak, amelyek lényege, hogy nem specifikusak egy adott feladatra, csupán általánosan képesek a többdimenziós adatokat kezelni valamilyen természetből származtatott jelenség imitálásával (például, hogy a szomszédos adatpontok hasonlóak lehetnek). A megerősítéses tanulási algoritmusok a gépi tanulási módszerek azon alcsoportjai, amelyek folyamatszabályozási feladatokra igencsak alkalmasak. Ezen algoritmusok lényege, hogy a környezettel folyamatos interakció során egy beépített döntéshozó megtanul felismerni különböző helyzeteket és azokban egyre jobb döntéseket hozni.

A doktori disszertációhoz ezért fő célul tűztem ki a megerősítéses tanulás fröccsöntésnél való alkalmazását, annak érdekében, hogy a jelenlegi Ipar 4.0 irányzatnak megfelelően egy algoritmus által a fröccsöntő gép beállítása könnyen elvégezhető legyen, akár különösebb emberi beavatkozás nélkül is. Ennek keretein belül kifejleszttem egy megerősítéses tanuláson alapuló módszert, amellyel a terméket jelentősen befolyásoló két technológiai fázist (kitöltési és utónyomási fázis) lehet szabályozni, adott kritériumok alapján. Céлом továbbá az így kialakított módszer korlátjainak megismerése, elemzése, valamint a módszer alkalmazása különböző szerszámok és alapanyagok alkalmazása esetén. Ehhez fröccsöntési kísérleteket és végeselemes szimulációs kísérleteket végzek, amely adatokból különböző tanulási eseteket szimulálok majd a fejlesztett módszerrel. Mivel a fröccsöntési technológia számos paramétertől függ, így céлом, hogy az algoritmus olyan esetekben is hatékonyan alkalmazható legyen, amikor eltérő forrásból (szerszám, alapanyag, technológiai paraméterek, szimuláció) származó adatokat alkalmazok a betanításhoz, mint később a gépbeállításhoz.

2. Szakirodalmi áttekintés

Az általam elemzett irodalomból több hiányosság is kimutatható, amelyek problémát jelenhetnek az aktuális ipari forradalom (az ipar 4.0) következtében felmerülő elvárások miatt. A szakirodalomból egyértelmű a tendencia a szenzoros és gépi adatok feldolgozásának szükségletére, azonban várható jelenség, hogy a munkakörök jelentős változáson fognak keresztül menni, ahogyan az a korábbi ipari forradalmaknál is tapasztalható volt. Ennek függvényében a fröccsöntésnél is fontos az egyszerűbb, monotonabb, vagy éppen emberi beavatkozást nem feltétlen igénylő munkafolyamatok gépesítése a jövőben (mint például a gépbeállítás).

Számos eljárás létezik a gépbeállításra, azonban ezek mindig egy-egy speciális gyártási esetre vonatkoznak (adott szerszám, alapanyag, gép kombinációjára), az irodalomban nem részletezik azt, hogy miként lehetne eltérő alapanyagú, esetleg eltérő geometriával rendelkező adatoknál a korábban megszerzett információkat, modelleket alkalmazni. Ez rendkívül nagy hiányosság, ugyanis ipari környezetben egy adott cég általában nemcsak egyféle termékkel dolgozik, sőt gyakran szükség lehet alapanyag, termék geometria változtatásra különböző mechanikai követelmények, környezettudatossági szempontok (selejt és csatorna újrahasznosítás) vagy éppen külső kényszer miatt (megszűnik a beszállító, eltérő alapanyag formulával dolgoznak stb.).

A feldolgozott irodalmakból látható, hogy a szimulációs technikák rendkívül hasznosak lehetnek a gép beállításához, adott termék esetén a technológiai optimum megkereséséhez, de ehhez pontos szimulációkra van szükség, amihez az alapanyag tulajdonságokat ki kell mérni, különben nagy eltérés lesz a valós és szimulált eredmények között. Ezzel azonban újra csak további mérések szükségesek a gyártás előtt. Mi több ezek a mérések gyakran olyan eszközöket igényelhetnek, amik az adott ipari környezetben nem jellemzően használatosak, így ezekhez a mérésekhez szakembereket és berendezést kell szerezni, vagy külső laboratóriumokból kell azokat a vizsgálatokat megrendelni.

A megerősítéses tanulás egy rendkívül hasznos eljárás lehet a gép beállítására és akár folyamat szabályozásra is a működési elve alapján. A tudományos folyóiratokban jelenleg viszonylag kevés cikk foglalkozik a megerősítéses tanulás fröccsöntésnél való alkalmazásáról, ezek közül is csak pár a folyamat szabályozásáról. Emellett a megerősítéses tanulásról szóló szabadalmak többségben szűkszavúak a szabadalmat érintő algoritmus működését illetően, ritkán tisztázzák, hogy konkrétan melyik megerősítéses tanulási módszer alkalmazására vonatkozik a szabadalmuk, vagy éppen a szabadalomban közlik, hogy nem korlátozzák egyik

eljárásra se az ötletüket. Ezek a dokumentumok főleg a megerősítéses tanulás alkalmazásának módszerét védik, mint egy-egy algoritmus ötletet. Azok a szabadalmak, amelyek adnak pontos konkrétumokat az algoritmusról többségében a Q-tanuló algoritmust esetleg a cselekvő-kritikus algoritmust említik, de ezeket általában diszkontálással, ami folytonos szabályozás esetén kevésbé hasznos lehet.

A cselekvő-kritikus algoritmus rendkívül ígéretesnek tűnik a szabályozási és tanulási módszere alapján a gép beállítására. A betanítása során megtanult irányelvek esetleg hasznosak lehetnek különböző típusú geometriák esetében is, ugyanis hasonló minőség kritériumok esetében a fröccsöntő gépet hasonló paraméterekkel lehet szabályozni az irodalom szerint, mivel csupán az optimális értékek különböznek. Ehhez valószínűleg a megfelelő állapot definíció segítségével az algoritmus képes lehet igazodni, így a fröccsöntőgép beállítását el tudná végezni, sőt akár valamilyen hiba esetén az cél értéktől való eltérést is vissza tudná szabályozni egy új optimumra. A szabályozással foglalkozó tanulmányok többségében a cselekvő-kritikus algoritmusnál neurális hálókat alkalmaznak, gyakran sok rejtett réteggel. Ezek betanításához a szakirodalom szerint nagy adatsorra van szükség, ezért érdemes lehet egy másik megoldást, az állapot aggregációt alkalmazni, ami leegyszerűsítheti a problémát.


Az irodalomkutatás alapján a következő feladatok lennének lényegesek a hiányosságok feloldására:

- a cselekvő-kritikus algoritmus alapú módszer fejlesztése a kitöltési és utónyomási fázis beállítására, ugyanis ezek a fázisok nagy jelentőséggel bírnak a termékminőség szempontjából,
- az így fejlesztett módszerhez szükséges előkísérletek módszertanának vizsgálata, lehetséges kísérlettervek hatásának vizsgálata a tanulási folyamatra,
- az említett módszer alkalmazhatóságának vizsgálata új környezetben: eltérő alapanyagánál, különböző kialakítású gátak, termék geometriák esetén,
- a módszer alkalmazhatóságának vizsgálata végeselemes szimulációs adatok alapján, a főbb kritériumok meghatározása, amelyek mentén alkalmazhatók egyszerűsített szimulációk is.

3. Kutatómunka összefoglalása

3.1. Felhasznált alapanyagok, termék geometriák

A kutatásom során hat különböző termék geometriában, vagy gátrendszerben eltérő gyártmánnal végeztem kitöltési és utónyomás beállítási kísérleteket fröccsöntéssel (1. ábra). Ezek között voltak egyszerűbb lapka termékek, melyek névleges mérete 80x80 mm, vastagságuk pedig 1 mm és 2,5 mm között változott. Ezek a termékek többségében filmgáttal rendelkeztek („A” és „C” típusú gátrendszer), vagy a termék két sarkában egy-egy oldalgáttal voltak ellátva („B” típusú gátrendszer). Emellett bonyolultabb termékgeometriákat is alkalmazta: a 16 fészkes kis fedéltermékeket, illetve egy kétfészkes fedéltermék kialakítást. A vizsgálataim során három féle alapanyagból gyártottam próbatesteket: akrilnitril-butadién-sztirolból (ABS), polipropilénből (PP), illetve politejsavból (PLA).



1. ábra A kutatás során használt különböző termék geometriák elosztócsatornával

- a) és b) 1,2 mm vastag lapka rendre „A” és „B” típusú gátrendszerrel,
 c) és d) 1 mm és 2,5 mm vastag lapka „C” típusú gátrendszerrel,
 e) fedéltermék, f) kis fedéltermék

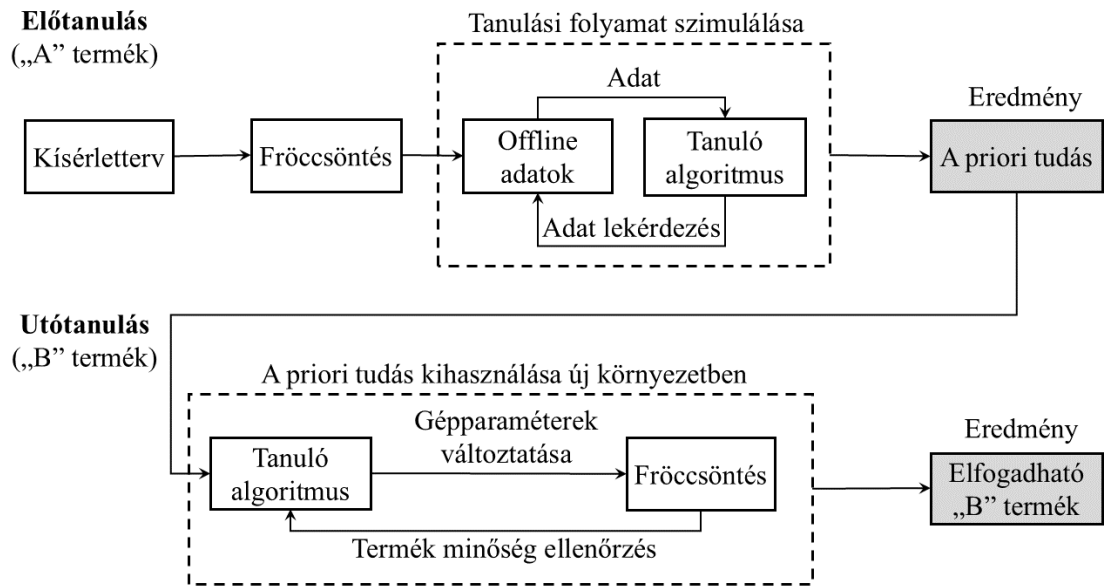
Az egyes termékgeometriákat a kitöltés beállításánál különböző átkapcsolási térfogat és befröccsöntési térfogatáramok esetén gyártottam le. Ezeknél a vizsgálatoknál a fészeküregben mérhető nyomást, a próbatestről készült képet, illetve a termék kitöltési időket alkalmaztam, mint kritériumok. Az egyes termékeknél tehát minden esetben definiáltam a maximálisan kialakulható üregnyomást, a kitöltés idejének a maximum értékét. Emellett a szerszámnyitást követően képet készítettem a próbatestekről, amit egy általam programozott képfeldolgozó rendszer kiértékelte és minősítette a fészek kitöltöttségi arányát. Ezekből a kritériumokból definiáltam egy kitöltési állapotjellemzőt, amelyet az általam létrehozott megerősítéses tanuláson alapuló gépbeállító algoritmus használt fel. Az utónyomás beállítása esetén a

termékek tömegéből definiáltam az utónyomási állapotjellemzőt, és itt az algoritmus az utónyomás nagyságát, illetve az utónyomás idejét tudta szabályozni.

3.2. Az alkalmazott tanuló algoritmus és a vizsgálati módszer

A vizsgálataimhoz egy általam programozott és továbbfejlesztett cselekvő-kritikus algoritmust használtam. Az algoritmus egy softmax függvényt használ az irányelvnek megbecslésére, valamint az aggregált állapotoknak a minőségét egy bilineáris függvénnyel tudja megbecsülni. Emiatt az algoritmusnak fontos paraméterei többek között az akció készlete, az állapotaggregáció határai, a célérték tűrésmezője, a tanulási paraméter nagysága, a tanítás során végzett lépések száma. Emellett mivel az algoritmus döntéshozása sztochasztikus, így szintén fontos paramétere, hogy hány véletlen tanulási esetet szimulál az adott adatkészletből. Emellett a programja tartalmaz egy általam definiált visszaállítási mechanizmust, amely adott tanulási lépést követően az algoritmust visszahelyezi a kezdő pozíciójába. További újítás az algoritmusban a szokásos cselekvő-kritikus algoritmusokhoz képest, hogy megadható a mohó akciók száma, illetve kumulált valószínűsége is, amivel az algoritmus kiaknázási-felfedezési képessége definiálható. Az algoritmus a tanulása során a fröccsöntőgép technológiai paramétereit változtatja, és azt figyeli, hogy a termék minőségét jellemző kritériumok, hogy változnak. A gépbeállítás célja természetesen, hogy minél kevesebb fröccsöntési ciklusból történjen meg a gépbeállítás.

Az általam kifejlesztett gépbeállítási módszer lényegében két fő részre bontható (lásd 2. ábra). Az első lépés egy előtanulásra, amikor a tanuló algoritmust offline fröccsöntési adatokból betanítom egy adott termék beállítására. Ekkor az algoritmus 100 véletlen tanulási esetet futtat le, amelyek eredményeként meghatároz egy a priori tudást, ami a különböző állapotokban fontos lépéseket, irányelvet foglalja magába.

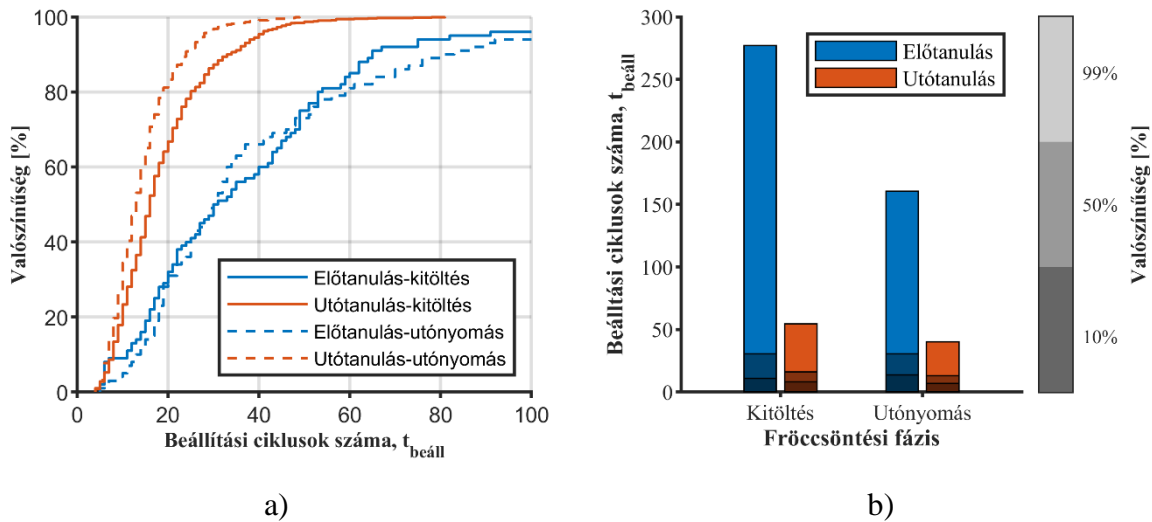


2. ábra A kidolgozott gépbeállítási módszer

Ezt a részt követi az utótanulás, amikor az algoritmus ezt a korábban megszerzett a priori tudást használja fel egy újabb termék esetében online gépbeállítás során. Az elemzéseim során ezt az utótanulást ugyancsak offline adatokon elemeztem elsősorban különböző forrásokból származó a priori tudásokkal. Emellett viszont végeztem validáló méréseket, ahol az utótanulás tényleges online gépbeállítás volt.

3.3. Eredmények

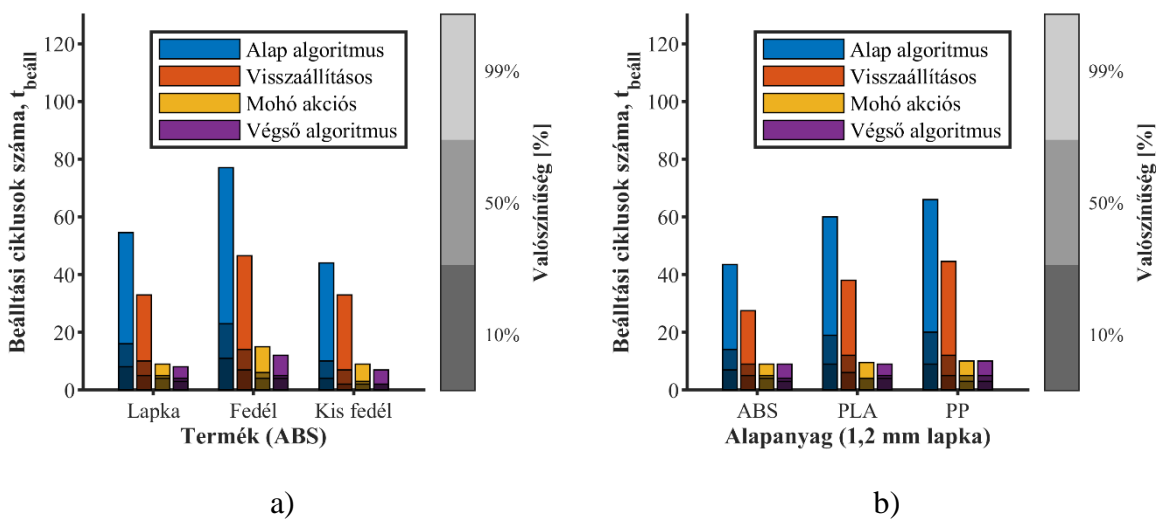
Annak érdekében, hogy jó képet kapjak az algoritmus teljesítményéről offline utótanulás esetén 1000 tanulási esetet szimuláltam. Mivel ezek az esetek valójában a fröccsöntőgép beállítását szimulálják, így elemzéseim során azt vizsgáltam, hogy az egyes algoritmus paraméterek, előtanulási esetek következtében az 1000 esetben milyen sok tanulási lépés (más néven fröccsöntési ciklus) kell a fröccsöntőgép beállításához. Az algoritmus teljesítményére tehát a gépbeállításához szükséges ciklusok számának kumulált eloszlását alkalmaztam. A két fröccsöntési fázisnál az általam alkalmazott gépbeállítási módszer hatékonyságát szemlélteti a 3. ábra. jól látható, hogy az utótanuláshoz szükséges ciklusok száma jelentősen kevesebb (mind a kitöltés, mind az utónyomás beállításánál).



3. ábra Az elő- és utótanulás során a) szükséges gépbeállítási ciklusok számának valószínűsége
b) a 10%, 50% és 99%-os valószínűségekhez tartozó beállítások szemléltetése

3.3.1. Algoritmus paraméterek optimalizálásának hatása

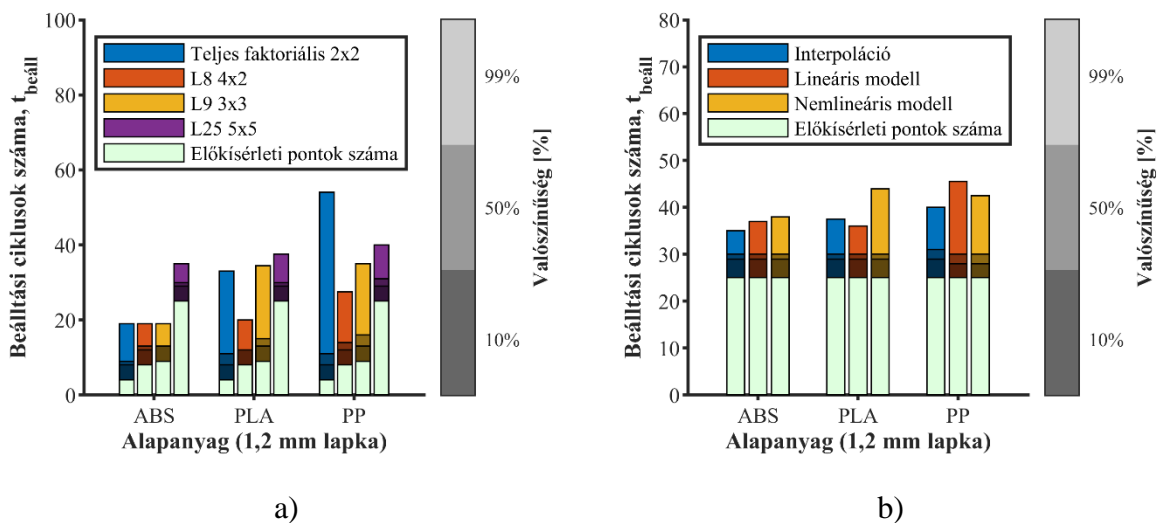
Az általam alkalmazott gépbeállítási módszert megvizsgáltam különböző algoritmus paraméterek esetén. Ezek között szerepelt az előtanulás során vizsgált szimulációk száma, a tanulási paraméter, az akciók készlet, és az állapotaggregáció típusa is. Emellett megvizsgáltam, hogy milyen módon változik az algoritmus teljesítménye, amennyiben kibővítem az algoritmus működését a mohó akciókkal és újratekintési mechanizmussal. Az eredményekből jól látható volt, hogy ezek a mechanizmusok jelentősen csökkentették az utótanulás során szükséges gépbeállítási ciklusok számát (4. ábra). A végső algoritmus ezt a két mechanizmust együtt tartalmazza és a későbbiekben is ehhez tartozó beállításokat használtam az elemzéseimhez.



4. ábra A különböző algoritmusok teljesítménye különböző a) termék geometriáknál, b) alapanyagoknál

3.3.2. Az előkísérletek és köztes pontok becslésének hatása

Az előtanulás során az offline tanuláshoz használt adatsor jelentős hatással lehet az algoritmus teljesítményére. Ezért különböző tanulási eseteket szimuláltam, amikor az előtanuláshoz használt adatsort különböző kísérlettervek alapján állítottam elő. Összesen 15 különböző kísérlettervből tanítottam be a tanuló algoritmust, majd a teljes ismert adatsorokon utótanulást végeztem. Emellett megvizsgáltam, hogy a kísérleti pontok közti adatok megbecslésénél használt modellezési formák milyen hatással vannak a tanítás hatékonyságára. Ehhez háromféle köztes pont becslési módszert használtam: lineáris interpolációt, lineáris modelleket, illetve nemlineáris modelleket. Különböző termékeken, illetve különböző alapanyagból gyártott termékeknél jól látható volt, hogy a tanuláshoz nincs egyértelműen kiemelkedő kísérletterv, vagy modellezési eljárás (5. ábra). A tanulás hatékonyságát inkább az befolyásolja, hogy az előtanulásnál használt adatsorban a céltartomány és annak közvetlen környezete (mellette lévő aggregált állapotok) milyen mértékben jól van reprezentálva. Bizonyos esetekben a céltartomány például olyan keskeny volt az egyes előtanulásoknál, hogy az algoritmus képtelen volt olyan akciót találni, amivel beletalált volna.

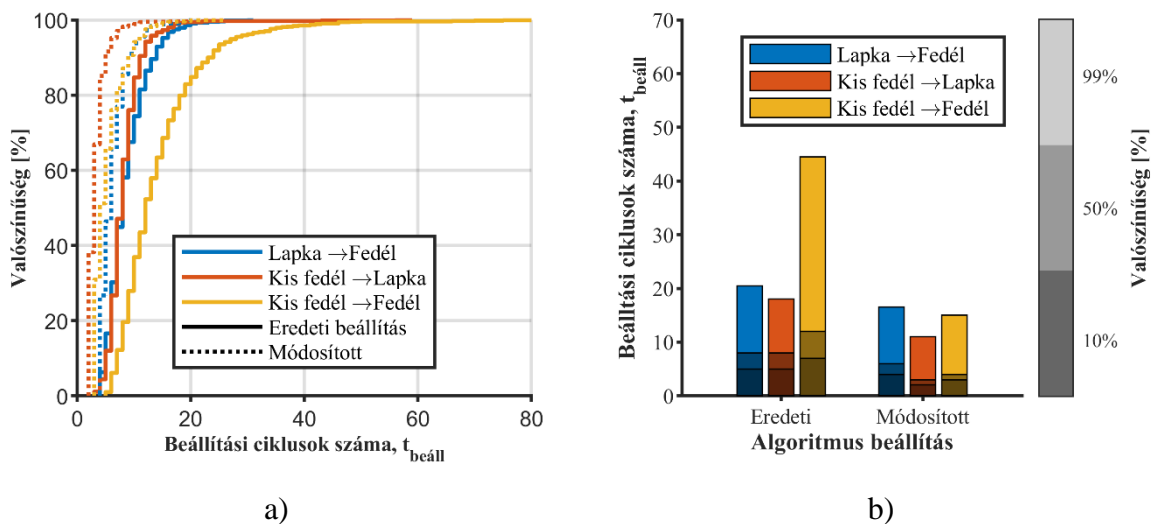


5. ábra a) Az előtanuláshoz használt kísérlettervek és b) köztes pontok becslésének módjának hatása

3.3.3. Eltérő termékből való tanulás hatása

Az általam kidolgozott módszer lényege, hogy a tanuló algoritmus előtanulásnál olyan technológiai hatásokat ismer meg, amely hatások a fröccsöntött termékek jelentős részénél hasonlóan jelen van. Ebből következően az algoritmus képes lehet ezt az a priori tudást újabb környezetben (egy másik termék esetén) is felhasználni. Emiatt vizsgálatokat végeztem olyan esetekre amikor a termék geometriája vagy alapanyag eltérő volt az elő- és utótanulás során.

Az eredményekből jól látható volt, hogy mivel az egyes termékeknel a technológiai paraméterek hatása bizonyos mértékben más hatást eredményez, így a tanulás néhány termék kombinációnál lassabb lett. Ezek az esetek azonban javíthatók az algoritmus bemeneteinek bizonyos mértékű módosításával. Ajánlott az eredmények alapján a feltöltési mechanizmus használata, amivel az algoritmus a priori tudásában az előtanulás során nem tapasztalt állapotok feltölthetők a szélső ismert értékekkel. Ezzel a technológia hatásában való eltérések egy része kompenzálható. Jól látható volt emellett, hogy jelentős termék térfogatbéli eltérés esetén érdemes lehet az átkapcsolási térfogatra vonatkozó akciókat arányosítani a termékek térfogata mentén. Erre azért volt szükség, mert azonos átkapcsolási térfogat változtatás különböző mértékű hatást érhet el, amennyiben az előtanulásnál használt termék térfogata jelentősen eltér az utótanulásnál alkalmazott termék térfogatától. Bizonyos esetekben az utótanulás során használt termék céltartománya keskeny volt a lehetséges akciókhoz mérten az elemzés során. Ilyenkor az eredményekből jól látszik, hogy az előtanulásnál használt céltartomány szűkítésével jelentősen javítható az algoritmus teljesítménye. Ennek hátterében az a jelenség áll, hogy az algoritmus már előtanulásnál kénytelen rátanulni arra, hogy a célnál csak kisebb akciókat választhat. Ezekkel a módosításokkal az algoritmus teljesítménye megközelítheti azt, mint amikor az elő- és utótanulásnál is azonos adatsorból tanul (6. ábra).



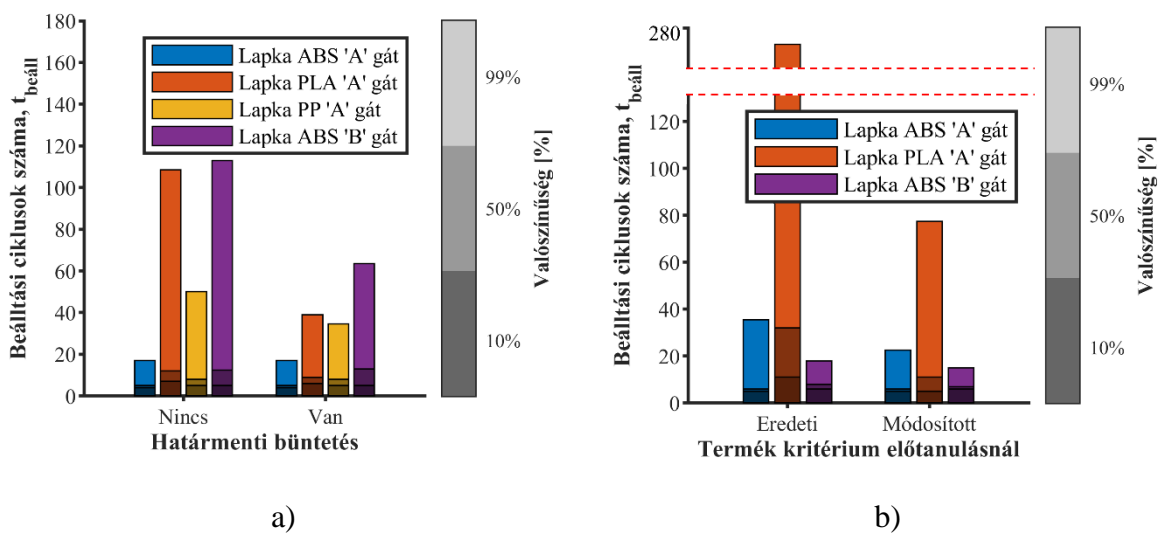
6. ábra Az algoritmus módosításaival elérhető javulás az utótanulásnál a) a teljes valószínűségi görbékkel b) 10%, 50% és 99%-os valószínűségek esetén

3.3.4. Szimulációs adatokból való tanulás hatása

A végeleges szimulációk rendkívül elterjedtek az iparban és jó rálátást adhatnak a fröccsöntőgép paramétereinek hatására. Emiatt viszonylag pontatlan, kis peremfeltételű szimulációkból származó adatsorokat is használtam az előtanulásnál, hogy elemezzem azok

hatását. Ezekből az elemzésekből az volt látható, hogy a kitöltés beállításánál érdemes a vizsgálati tartományon túlmutató akciókat büntetni az utótanulás során. Erre azért lehet szükség, mivel bizonyos szimulációs programokkal a kitöltés szimulálásánál a 100%-os kitöltöttségi állapot felett nem lehet túltölteni a szerszámüreget, pedig ez a valóságban könnyen előfordulhat. Ilyen módon hiányos adatsorból az algoritmusnál törekedni kell arra, hogy a szélső tartományokból minél előbb vissza tudjon találni, amire a büntetés megfelelő.

Az utónyomás beállítása esetén a pontatlan szimulációk következtében bizonyos termékgeometriáknál/alapanyagoknál a szimulációs adatsor nem tartalmazta a valós adatsorból definiált célértéket. Ezekben az esetekben érdemes lehet az előtanulási céltartományt megváltoztatni, így az algoritmusnak lehetősége van megtanulni azt, hogy miként tud a cél környezetében viselkedni. Ezek a módosítások a szimulációból származtatott a priori tudás hatékonyságán jelentősen javítottak, bizonyos esetekben közel 200-zal kevesebb ciklusra volt szükség az utótanulásnál, mint a módosítások nélkül (7. ábra).



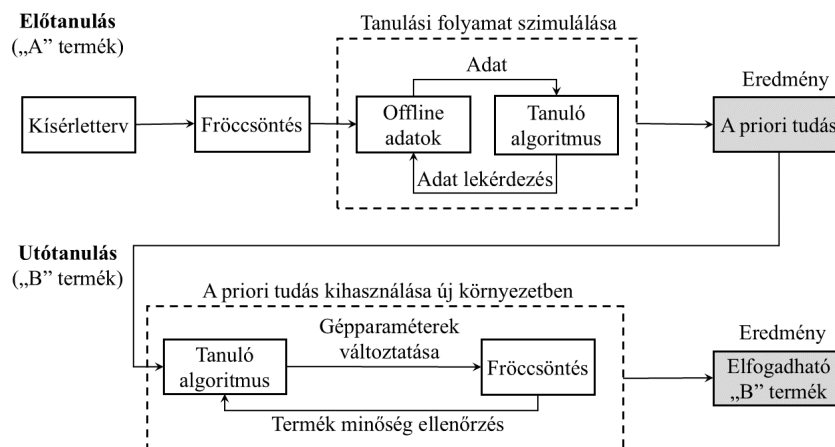
7. ábra A szimulációs adatoknál alkalmazott algoritmus módosítások hatása a) a kitöltési fázis beállításra, b) az utónyomási fázis beállítására

4. Tézisek

I. Tézis

Kidolgoztam egy optimalizáló folyamatszabályozási módszert, ami hőre lágyuló polimer alapanyagú, lapkaszerű termékek esetén a fröccsöntés kitöltési fázisát a fészekben kialakult maximális nyomás, a fészek kitöltési idő és a termékről készült kép alapján; az utónyomási fázist pedig a termék tömeg alapján képes az adott jellemzőkből definiált tűrésmezőn belüli értékre beállítani. Az eljárás egy általam módosított cselekvő-kritikus algoritmuson alapszik. Az algoritmus a technológiai változókat tudja módosítani a terméket jellemző állapot alapján, állapotaggregáció és diszkrét akciókészlet használatával. A módszer lényege, hogy egy előkísérleti adatsoron (offline) betanítva (előtanulás) az algoritmust, az képes a fröccsöntőgépet egy másik termék/beállítás esetén, az előtanuláshoz képest jelentősen kevesebb ciklus alatt beállítani (utótanulás), az előtanulás során nyert a priori tudással [1-5].

Állításaimat hat különböző termék és elosztócsatorna geometria, valamint három alapanyag (ABS-Terluran GP-35, PP-Tipplen H145F, PLA-Ingeo 3100HP) esetén igazoltam. A méréseimhez négy különböző fröccsöntőgépet alkalmaztam (Arburg Allrounder 270S 400-170, Arburg Allrounder 320C 400-170, Arburg Allrounder 420C 1000-290, Arburg Allrounder 470A 1000-290). Méréseim során az a priori tudás használatával a kitöltés beállításához átlagosan 195 ciklussal (minimum:34, maximum:427, medián:165) kevesebbre volt szükség (a tanulási esetek 99%-ban), mint anélkül. Az utónyomás esetén a beállításához átlagosan 203 ciklussal (minimum:55, maximum: 378, medián: 205) kevesebbre volt szükség (a tanulási esetek 99%-ban).



8. ábra A kidolgozott képbeállítási módszer

II. Tézis

Különböző lapkaszzerű termékek és alapanyagok esetén, a tanulási folyamatok szimulálásával, illetve online mérésekkel bizonyítottam, hogy az általam kidolgozott optimalizáló folyamatszabályozási módszerben a cselekvő-kritikus algoritmus utótanulás során több mohó akcióval és az előtanulási során egy újrakezdési mechanizmussal való együttes módosítása jelentősen csökkentheti a fröccsöntőgép beállításához szükséges ciklusok számát. Igazoltam továbbá, hogy a gépbeállítás akkor a leggyorsabb, ha az előtanulás során az újrakezdési mechanizmust 30 alkalommal 100 lépésen keresztül végzem, valamint az utótanulás során a mohó akciók számát 5-re szűkítem, míg az egyes mohó akciók 90%-os kumulált valószínűséggel választhatók [1, 2, 4, 5]

Állításaimat négy különböző termék geometria, valamint három alapanyag (ABS-Terluran GP-35, PP-Tiplen H145F, PLA-Ingeo 3100HP) esetén igazoltam. A méréseimhez négy különböző fröccsöntőgépet alkalmaztam (Arburg Allrounder 270S 400-170, Arburg Allrounder 320C 400-170, Arburg Allrounder 420C 1000-290, Arburg Allrounder 470A 1000-290). Méréseim során a kitöltési fázis optimalizálásához átlagosan 53 ciklussal (minimum: 35, maximum: 65, medián: 54) kevesebbre volt szükség az adott módosításokkal (a tanulási esetek 99%-ban). Az utónyomási fázis optimalizálásához átlagosan 40 ciklussal (minimum: 13, maximum: 71, medián: 38) kevesebbre volt szükség az adott módosításokkal (a tanulási esetek 99%-ban).

III. Tézis

Különböző lapkaszzerű termékek és alapanyagok, valamint eltérő kísérlettervek és modellezési módszerek esetén igazoltam, hogy az általam kidolgozott optimalizáló folyamatszabályozási módszerben az a priori tudás hatékonyságát nem elsődlegesen az előtanuláshoz használt kísérletterv mérési pontjainak száma (minimum négy sarokpont esetén), elhelyezkedése vagy a köztes pontok szimulálására szolgáló modellezési módszer határozza meg, hanem az, hogy a kísérlettervből és a köztes pontok modellezéséből származtatott előtanulási állapot tér milyen mértékben reprezentálja az aggregált célállapotot és környezetét. Az előtanuláshoz alkalmazott állapot térnek szükséges tartalmaznia a célállapotot olyan módon, hogy az a lehetséges akciók függvényében elérhető legyen a tér bármely pontjából, valamint tartalmaznia kell legalább a célállapottal szomszédos két (cél alatti és cél feletti) állapotot is, máskülönben az utótanulás (vagyis gépbeállítás) során az optimalizáláshoz szükséges ciklusok száma jelentősen növekedhet [1,4-8]

Állításaimat négy különböző termék-csatorna geometria, három alapanyag (ABS-Terluran GP-35, PP-Tipplen H145F, PLA-Ingeo 3100HP), három modellezési eljárás, valamint 15 féle kísérletterv esetén igazoltam. A méréseimhez négy különböző fröccsöntőgépet (Arburg Allrounder 270S 400-170, Arburg Allrounder 320C 400-170, Arburg Allrounder 420C 1000-290, Arburg Allrounder 470A 1000-290), valamint Moldflow Insight 2019 végeeselemes szimulációkat alkalmaztam.

IV. Tézis

*Különböző lapkaszerű termékek és alapanyagok alkalmazása esetén, a tanulási folyamatok szimulálásával és online mérésekkel bizonyítottam, hogy **az általam kidolgozott optimalizáló folyamatszabályozási módszerrel eltérő alapanyagból vagy bizonyos mértékben eltérő geometriájú (lapkaszerű) termékből származó a priori tudással is közel hasonló ciklusszámmal lehet beállítani az új termékhez/alapanyaghoz a fröccsöntési fázist, mint azonos alapanyagú és geometriájú termékből származó a priori tudás felhasználásával.** Ehhez a következő módosítások szükségesek:*

- az előtanulás során a célállapot aggregációs tartományának csökkentése (a tűrés mező, illetve technológiai stabilitás függvényében),*
- az átkapcsolási térfogat változtatásához alkalmazott akciók nagyságának arányosítása a két tanulási folyamatban alkalmazott termék elméleti térfogatához viszonyítva,*
- a feltöltési mechanizmus alkalmazása, amennyiben az sejthető, hogy az előtanulásnál felfedezett aggregált állapotok száma kisebb, mint az új termék gépbeállításánál várható aggregált állapotok száma [1, 5].*

*Állításaimat hat különböző termék-csatorna geometria, három alapanyag (ABS-Terluran GP-35, PP-Tipplen H145F, PLA-Ingeo 3100HP) esetén igazoltam. A méréseimhez négy különböző fröccsöntőgépet (Arburg Allrounder 270S 400-170, Arburg Allrounder 320C 400-170, Arburg Allrounder 420C 1000-290, Arburg Allrounder 470A 1000-290) alkalmaztam. **Eltérő alapanyagú/geometriájú termékre utótanulás esetén a kitöltési fázis optimalizálásához átlagosan 3 ciklussal (minimum: -3, maximum: +10, medián: +1) többre volt szükség, mintha ugyanazon a termék-elosztócsatorna-alapanyag kombináción történt volna az optimalizálás az elő- és utótanulás során is (a tanulási esetek 99%-ban).** Az utónyomás optimalizálásához hasonló esetben átlagosan 4 ciklussal (minimum: -4, maximum: +23, medián: +2) többre volt szükség (a tanulási esetek 99%-ban).*

V. Tézis

Különböző lapkaszerű termékkel és különböző alapanyagokon végzett végeselemes szimulációkkal, tanulási folyamat szimulálásával, valamint online mérések segítségével kiterjesztettem az általam kidolgozott optimalizáló folyamatszabályozási módszer alkalmazását pontatlan, kevés peremfeltételű végeselemes szimulációkból származtatott a priori tudás alkalmazására. A kiterjesztett módszerrel hasonló ciklusszámmal lehet valós termék fröccsöntésekor a kitöltési- és utónyomási fázis optimalizálását elvégezni, mintha valós fröccsöntési adatokból származna az a priori tudás. A következő módosítások szükségesek a szimulációknál felmerülő pontatlanságok korrigálására:

- a kitöltés beállításához a vizsgálati határon kívül mutató akciók további (negatív) jutalommal való büntetése,*
- a feltöltési mechanizmus alkalmazása,*
- az utónyomási beállításához esetlegesen a cél érték, illetve aggregációs tartomány változtatás [1, 5].*

Állításaimat három különböző termék-csatorna geometria, illetve három alapanyag (ABS-Terluran GP-35, PP-Tipplen H145F, PLA-Ingeo 3100HP) esetén igazoltam. A vizsgálataimhoz két különböző fröccsöntőgépet (Arburg Allrounder 270S 400-170, Arburg Allrounder 320C 400-170), valamint Moldflow Insight 2019 végeselemes szimulációkat alkalmaztam. Méréseim során a kitöltési fázis optimalizálásához átlagosan 28 ciklussal (minimum: 8, maximum: 52, medián: 27) többre volt szükség a végeselemes szimulációs adatokból származtatott a priori tudással, mintha az adott termékek valós fröccsöntési adataiból meghatározott a priori tudást alkalmazta volna az algoritmus (a tanulási esetek 99%-ban). Az utónyomási fázis optimalizálásához pedig átlagosan 4 ciklussal (minimum: 0, maximum: 17, medián: 1) több beállítási lépésre volt szükség a szimulációból származtatott a priori tudással (a tanulási esetek 99%-ban).

5. Publikációk

1. Párizs R. D., Török D.: An experimental study on the application of reinforcement learning in injection molding in the spirit of Industry 4.0. *Applied Soft Computing*, **167**, 112236 (2024). (<https://doi.org/10.1016/j.asoc.2024.112236>)
2. Párizs R. D., Török D.: Fröccsöntött termékek zsugorodásából adódó alakdeformáció kompenzálása, szerszámüreg-nyomás alapján. *Polimerek*, **8**(5), 153-160 (2022).
3. Párizs R. D., Török D., Ageyeva T., Kovács J. G.: Machine learning in injection molding: an industry 4.0 method of quality prediction. *Sensors*, **22**(7), 2704 (2022). (<https://doi.org/10.3390/s22072704>)
4. Párizs R. D., Török D., Ageyeva T., Kovács J. G.: Multiple in-Mold sensors for quality and process control in injection molding. *Sensors*, **23**(3), 1735 (2023). (<https://doi.org/10.3390/s23031735>)
5. Párizs R. D., Török D.: How to use prior knowledge for injection molding in industry 4.0. *Results in Engineering*, **23**, 102667 (2024).
6. Párizs R. D., Török D.: A gyártási paraméterek hatása a fröccsöntött termékek színhomogenitására fűtött csatornás szerszámokban. *Polimerek*, **8**(6), 259-264 (2022).
7. Kiss B., Párizs R. D., Tóth C., Török D., Kovács N. K.: Anyagextrúzió alapú additív gyártástechnológiával készült termékek anizotróp viselkedésének elemzése. *Polimerek*, **9**(5), 155-160 (2023).
8. Tomin M., Lengyel M. Á., Párizs R. D., Kmetty Á.: Measuring and mathematical modeling of cushion curves for polymeric foams. *Polymer Testing*, **117**, 107837 (2023). (<https://doi.org/10.1016/j.polymeresting.2022.107837>)