UAB
Universitat Autònoma de Barcelona

Dipòsit digital de documents de la UAB

This is the **published version** of the bachelor thesis:

Guil Puntes, Pol. *Eines intel·ligents per a l'ajust de sistemes industrials.* Treball de Final de Grau (Universitat Autònoma de Barcelona), 2026 (Grau en Enginyeria de Dades)

This version is available at https://ddd.uab.cat/record/337347

under the terms of the  license.

Eines Intel·ligents per a l'Ajust de Sistemes Industrials

Pol Guil Puntes

Resum— L'envasament industrial requereix un control precís del pes de cada producte: les màquines envasadores i els fabricants tendeixen a sobredosificar per evitar que cap unitat quedi per sota del pes legal, generant una pèrdua o regal de matèria prima, i rebutjos quan el pes surt de les toleràncies establertes. Aquest treball, desenvolupat en col·laboració amb Varpe Control de Peso S.A., explora com ajustar de manera progressivament més intel·ligent els paràmetres d'un controlador PID per minimitzar aquest problema. Es parteix de la construcció d'un simulador validat amb dades reals de producció, que permet caracteritzar com les diferents configuracions de paràmetres afecten el comportament del sistema i identificar el punt d'equilibri (*Trade-off*) existent entre el nombre de rebutjos i la precisió del pes mig. A partir d'aquesta base, s'implementen mètodes d'optimització automàtica, un algorisme genètic i un esquema adaptatiu que reajusta els paràmetres al llarg de la producció, i finalment, un model basat en aprenentatge automàtic capaç d'anticipar la configuració òptima sense necessitat de cap cerca en temps real.

Paraules clau—Controlador PID, pesatge dinàmic industrial, envasadora, rebutjos, toleràncies, pes mig, optimització de paràmetres, grid search, frontera de Pareto, algorisme genètic, control adaptatiu, aprenentatge automàtic.

Abstract— Industrial packaging requires precise control over each product's weight: filling machines and manufacturers tend to overdose in order to avoid units falling below the legal weight, generating raw material waste or giveaway, and rejections when the weight falls outside the established tolerances. This work, developed in collaboration with Varpe Control de Peso S.A., explores how to progressively and intelligently tune the parameters of a PID controller to minimise this problem. The starting point is a simulator validated against real production data, which allows different parameter configurations to be characterised in terms of their effect on system behaviour and identifies the trade-off between the number of rejections and mean weight accuracy. Building on this foundation, automatic optimisation methods are implemented, a genetic algorithm and an adaptive scheme that readjusts parameters throughout production, and finally, a machine learning model capable of anticipating the optimal configuration without any real-time search.

Index Terms—PID controller, dynamic industrial weighing, filling machine, rejections, tolerances, mean weight, parameter optimisation, grid search, Pareto frontier, genetic algorithm, adaptive control, machine learning.

1 Introducció - Context del treball

Varpe Control de Peso S.A. és una empresa especialitzada en el disseny i fabricació de pesadores dinàmiques per a línies d'envasament industrial. Aquest TFG s'ha desenvolupat en col·laboració amb Varpe, amb l'objectiu d'explorar tècniques d'optimització automàtica per als algorismes de control que la seva maquinària utilitza.

Tots els productes envasats que arriben als supermercats han estat pesats i controlats abans de sortir de la fàbrica. Aquest control no és opcional: la legislació espanyola estableix que el pes mig dels envasos d'un lot no pot ser inferior al pes nominal declarat, i que la proporció d'envasos amb un pes per sota del mínim legal ha de ser prou petita per superar els controls estadístics establerts [1].

El compliment d'aquesta normativa és un requisit legal per a qualsevol fabricant que comercialitzi productes envasats al mercat espanyol.

En aquest control hi ha dos elements que treballen en seqüència: l'envasadora, que omple cada unitat (llauna, bossa, pot), i la pesadora dinàmica de Varpe, situada just després a la línia de producció, que pesa cada envàs en moviment a gran velocitat. La pesadora mesura el pes de cada unitat i, si queda fora de les toleràncies establertes, l'extreu de la línia perquè no arribi a mercat. Aquests envasos eliminats s'anomenen rebutjos.

En el cas de les pesadores de control com és el nostre cas a Varpe [2], els rebutjos són reprocessables, el producte torna al circuit de producció. En canvi, en pesadores

- *E-mail de contacte: Pol.Guil@autonoma.cat*
- *Treball tutoritzat per: Sergi Risueño*
- *Curs 2025/26*

situades al final de la línia de producció, els rebutjos poden ser destructius o no destructius, depenent de la matèria en qüestió i el seu procés d'envasament.

El sistema de control té una limitació física fonamental: opera sempre amb retard. Des que un envàs surt de l'envasadora fins que la pesadora el mesura, ja hi ha un cert nombre d'envasos en trànsit. Això significa que quan el sistema calcula una correcció basada en el que acaba de mesurar, la màquina ja ha produït nous envasos amb la configuració anterior, per tant el controlador sempre corregeix en passat. Per això, no és possible fer correccions envàs a envàs, sinó que cal treballar amb grups d'envasos i assumir que la correcció aplicada arriba als envasos posteriors amb un cert retard.

El problema central és la pèrdua de matèria primera causada per la sobredosificació. Com que cap envasadora és perfecta i la densitat del producte fluctua contínuament (per temperatura, humitat o lot de proveïdor), els fabricants tendeixen a envasar de més el pes nominal per assegurar-se que cap unitat queda per sota del mínim legal. L'objectiu del sistema de control és minimitzar aquest excés, mantenint el pes mig tan proper al nominal com sigui possible I generant els minim nombre de rebutjos.

La resta del document repassa breument el funcionament d'un controlador PID i planteja els objectius concrets del treball. A partir d'aquí, es descriu el desenvolupament seguint l'ordre en què s'ha anat construint el sistema: des del simulador inicial fins als algorismes d'optimització i predicció, per acabar amb els resultats obtinguts i les conclusions

2 Estat de l'art

Actualment, un dels mètodes de control més utilitzats en sistemes industrials de retroalimentació és el controlador PID [3][4][5] (Proporcional, Integral, Derivatiu), gràcies a la seva simplicitat i robustesa. En el context del pesatge dinàmic, el PID s'encarrega de calcular, a partir dels pesos mesurats, la correcció que s'ha d'enviar a l'envasadora per apropar la producció al pes objectiu.

La seva limitació principal és que assumeix un sistema estable, cosa que no sempre es compleix quan la densitat de la matèria primera varia al llarg de la producció. A més, trobar els valors adequats dels seus paràmetres no és trivial: depenen de les característiques de cada producte i de la pròpia màquina, i un mateix conjunt de valors pot funcionar molt bé en una producció i de manera mediocre en una altra. Ajustar-los manualment és un procés lent que normalment es basa en la prova i error i en l'experiència de l'operari.

3 Objectius

L'objectiu principal d'aquest treball és desenvolupar un simulador que permeti ajustar de manera progressivament més intel·ligent els paràmetres d'un controlador PID per a una envasadora industrial, millorant el comportament del sistema respecte a la configuració original. Aquest objectiu es concreta en tres objectius específics:

O1. Implementació del controlador PID: desenvolupar des de zero un simulador del controlador PID adaptat a les particularitats del pesatge dinàmic industrial, validat amb dades reals de producció de Varpe, i explorar el seu espai de paràmetres per entendre com afecten al comportament del sistema.

O2. Optimització automàtica: implementar un mètode que trobi automàticament una bona configuració de paràmetres sense necessitat d'ajust manual.

O3 — Algorisme predictiu: explorar la viabilitat d'un model basat en aprenentatge automàtic que sigui capaç d'anticipar la configuració més adequada per a properes produccions, sense haver de recalcular-la des de zero cada vegada.

4 Metodologia i Desenvolupament

El desenvolupament del treball ha seguit un procés iteratiu i incremental: es parteix d'un simulador bàsic que es va ampliant progressivament amb noves funcionalitats, a mesura que es contrasta el seu comportament amb les dades reals de producció. Cada nova versió incorpora les funcions de l'anterior, fins a arribar als algorismes d'optimització i predicció que es presenten en els darrers apartats.

4.1 Anàlisi exploratòria de la producció

El punt de partida del treball és una producció real de Varpe de 9.696 envasos, amb un pes objectiu (pes net) de 47,0 g. Cada envàs es classifica segons certes toleràncies, sent la més crítica T−1 (en aquest cas 44,5 g): el llindar inferior per sota del qual un envàs es considera rebuig i no pot sortir al mercat.

Una primera anàlisi sobre la totalitat de les mostres mostra que, sense cap control actiu, 976 envasos (un 10,07%) queden per sota de T−1 i són rebutjats, mentre que només 13 (un 0,13%) superen T+2. La mitjana global dels pesos és de 46,59 g amb una desviació estàndard d'1,87 g.

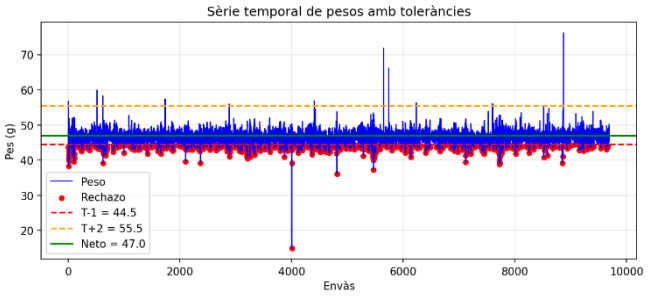

Figura 1. Sèrie temporal de la producció real de Varpe

La sèrie temporal mostra que la majoria de rebutjos corresponen a envasos lleugerament per sota del límit, però també s'observen valors extrems puntuals (com un envàs de només 14,9 g) que corresponen a anomalies mecàniques (errors de calibratge, envasos buits o dobles dosis) i no a una tendència sistemàtica de la producció.

4.2 Implementació del controlador PID

El controlador PID (Proporcional, Integral i Derivatiu) calcula una correcció a partir de l'error entre el pes desitjat i el pes mesurat, combinant tres termes: el proporcional respon a l'error actual, l'integral acumula l'error al llarg del temps i corregeix desviacions persistents, i el derivatiu anticipa la tendència a partir de la velocitat de canvi de l'error. El simulador s'ha construït de manera incremental, afegint progressivament les característiques que es descriuen a continuació.

La primera versió aplica la correcció envàs a envàs, però això no és realista perquè una envasadora industrial no pot ajustar cada unitat per separat. Per això s'introdueix el paràmetre N: el PID treballa per grups de N envasos, calcula la mitjana del grup, n'obté l'error respecte al pes objectiu i aplica la mateixa correcció a tot el grup següent. Aquest mateix valor de N defineix també el retard de stock: els N envasos posteriors al grup de càlcul ja estan en trànsit i reben la correcció anterior, mentre que la nova correcció no entra en efecte fins al cicle següent. Això reflecteix el retard explicat a la introducció: el controlador sempre actua sobre el que ja s'ha produït.

Finalment, s'incorpora un filtre que anomenem vàlid feedback que exclou del càlcul de la mitjana del grup els envasos amb codi d'error de la màquina i els envasos amb un pes molt allunyat del nominal (anomalies puntuals com envasos buits o dobles dosis). Aquest filtre només afecta la lògica interna del PID: tots els envasos, inclosos els filtrats, continuen comptant per a les mètriques finals (rebutjos i pes mig). Amb una configuració senzilla (N=10, Ki=0,025), el simulador ja redueix els rebutjos de 976 a 724 i apropa la mitjana global de 46,59 g a 46,93 g, molt a prop del pes net.

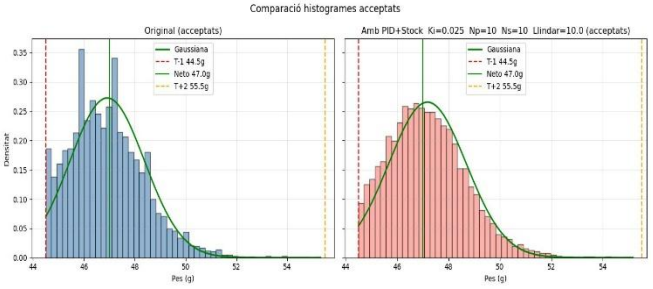

Figura 2. Comparació histogrames de pesos dins de toleràncies (acceptats)

4.3 Exploració de l'espai de paràmetres

Un cop validat el simulador, es duu a terme una exploració per força bruta amb un Grid Search [6] de 540 combinacions de paràmetres [7] (valors de N i tuples Kp/Ki/Kd). Els rangs explorats són: N ∈ {2, 10, 25, 50, 75, 100}, Kp ∈ [0,0; 0,1], Ki ∈ [0,007; 0,03] i Kd ∈ [0,0; 0,02], amb 18 tuples (Kp, Ki, Kd). La següent taula recull els rangs explorats per cada paràmetre:

Taula 1. Paràmetres del Grid Search explorats

Paràmetres	Valors Explorats
N_promig = N_stock	2, 10, 25, 50, 75, 100
Tuples Kp, Ki, Kd	(0.0, 0.01, 0.0), (0.0, 0.027, 0.0), (0.01, 0.007, 0.0), (0.03, 0.01, 0.0), (0.04, 0.008, 0.0), (0.05, 0.02, 0.0), (0.06, 0.025, 0.0), (0.07, 0.02, 0.0), (0.07, 0.02, 0.01), (0.07, 0.02, 0.02), (0.07, 0.025, 0.01), (0.07, 0.03, 0.0), (0.07, 0.03, 0.01), (0.08, 0.02, 0.01), (0.09, 0.025, 0.01), (0.1, 0.02, 0.02), (0.1, 0.03, 0.01), (0.1, 0.025, 0.0)

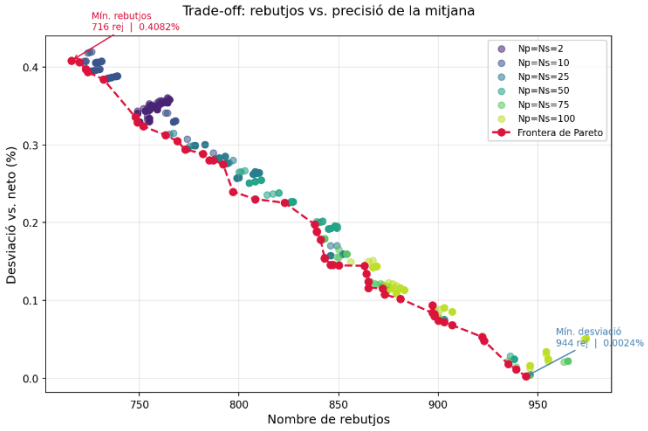

Figura 3. Trade-off on cada punt és una combinació de paràmetres del Grid Search

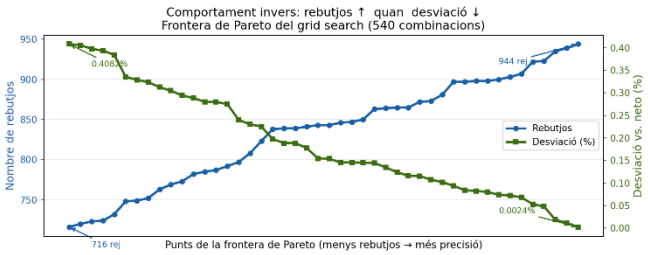

Figura 4. Relació lineal inversa entre les dues variables

Per a cada combinació es calculen dues mètriques: el nombre de rebutjos i el percentatge de desviació del pes mig respecte al pes objectiu.

Els resultats mostren una relació inversament proporcional clara entre les dues mètriques: les configuracions que menys rebutjos produeixen tenen una desviació més alta, i a l'inrevés. La frontera de Pareto [8][9][10] uneix les combinacions on no és possible millorar una mètrica sense empitjorar l'altra (és a dir, mostra el conjunt de combinacions de paràmetres més òptims per les dues variables), i estableix la referència de comparació per a tots els mètodes posteriors. Aquest trade-off és estructural del sistema: cap configuració minimitza alhora els rebutjos i la desviació, i quina prioritzar depèn de si els rebutjos del producte són destructius o reprocessables.

4.4 Optimització automàtica: algorisme genètic

El grid search té una limitació clara: el nombre de combinacions creix de manera combinatòria amb cada nou paràmetre. Per superar-ho s'implementa un algorisme genètic [11][12], que explora l'espai de paràmetres de manera eficient inspirant-se en la selecció natural. Una població de 50 individus (cadascun amb els quatre paràmetres Kp, Ki, Kd i N) evoluciona durant 40 generacions mitjançant selecció per torneig, creuament aritmètic i mutació gaussiana adaptativa.

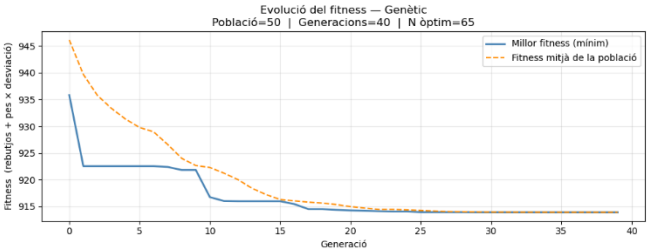

Figura 5. Evolució convergència de la funció fitness

La funció de fitness simula el PID complet sobre les dades reals i combina el nombre de rebutjos amb la desviació del pes mig, aplicant un factor d'escala perquè ambdues mètriques tinguin un pes comparable. La convergència es produeix sobretot entre les generacions 0 i 15. La millor configuració trobada és Kp=0,1838, Ki=0,1066, Kd=0,1244 i N=65, amb 714 rebutjos i un 0,347% de desviació del pes mig. Aquests valors no estaven predefinits: l'algorisme els descobreix de manera autònoma com el punt d'equilibri entre reactivitat i estabilitat.

4.5 PID Adaptatiu

Tot i que l'algorisme genètic troba una bona configuració global, aquesta pot no ser la millor per a cada moment de la producció. La densitat de la matèria prima varia al llarg del temps, la temperatura canvia, i el comportament de la màquina al principi d'un lot pot ser molt diferent del final.

En lloc d'assumir una única configuració de paràmetres per a tota la producció, l'enfocament adaptatiu divideix la producció en blocs i intenta aprendre la millor configuració per a cada un, reaccionant als canvis locals de manera progressiva.

Amb aquesta idea, s'implementa un PID adaptatiu [13] basat en Gain Scheduling [14][15]: la producció es divideix en blocs de W envasos, i al final de cada bloc s'aplica un grid search local que troba la configuració que minimitza els rebutjos d'aquell bloc. Aquesta configuració s'aplica al bloc següent. L'estat intern del controlador (correcció acumulada, integral i error anterior) es transmet entre blocs sense reiniciar-se, simulant el funcionament continu de la màquina real.

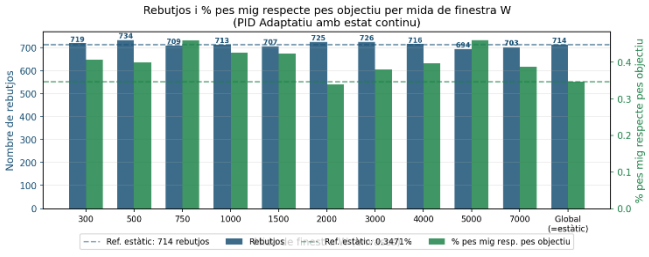

Figura 6. Rendiment per les diferents finestres W

S'han provat onze valors de W entre 300 i 9.696 envasos. Cinc d'ells milloren el resultat de l'estàtic genètic (714 rebutjos). W=2.000 ofereix el millor equilibri entre les dues mètriques (725 rebutjos, 0,340% de desviació), mentre que W=5.000 minimitza els rebutjos fins a 694 a costa d'una desviació lleugerament superior.

4.6 Model predictiu: Random Forest

L'enfocament adaptatiu reacciona al que acaba de passar, però sempre amb un cicle de retard: observa el bloc anterior per ajustar el següent. El model predictiu va un pas més enllà: en lloc de reaccionar, vol anticipar la configuració òptima abans que el bloc arribi. La idea és que cada envasadora té un comportament propi, i si s'aconsegueix aprendre com es comporta a partir de prou produccions, es pot predir com actuarà en el futur sense necessitat de fer cap cerca en temps real.

Per aconseguir-ho, es generen produccions sintètiques que imiten el comportament de la màquina real, s'extreu de cada una la configuració òptima per a cada bloc, i amb totes aquestes dades s'entrena un model d'aprenentatge automàtic capaç de predir la millor configuració per al bloc següent. Com que només es disposa d'una producció real, es generen 60 produccions sintètiques calibrades per assemblar-se a la real (sigma ~ 1,45 g, ~10% de rebutjos), combinant una deriva lenta (random walk suavitzat) amb soroll gaussià per envàs.

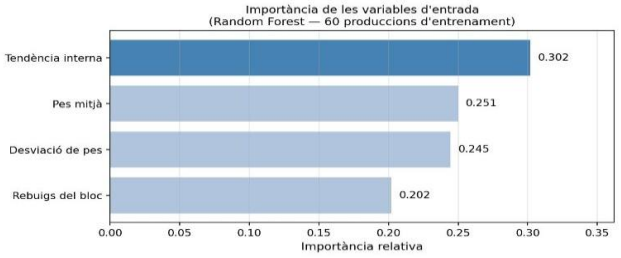

Figura 7. Importància relativa de les 4 característiques

Cada producció es divideix en blocs de 500 envasos. Per a cada bloc s'extreuen quatre variables: el nombre de rebutjos, la desviació del pes mig, el pes mig dels acceptats i la tendència interna (diferència entre la segona i la primera meitat del bloc). El target és la configuració òptima (Kp, Ki, Kd) per al bloc següent, obtinguda per grid search exhaustiu.

El model escollit és un Random Forest [16][17]. Per entendre com funciona, cal partir d'un arbre de decisió: un model que aprèn a predir un valor fent preguntes encadenades sobre les dades d'entrada. Per exemple, primer pregunta si la tendència del bloc és negativa; si ho és, pregunta si hi ha molts rebutjos; i al final de cada camí dona com a resposta la mitjana de les configuracions òptimes dels exemples d'entrenament que van seguir aquell mateix recorregut. El problema dels arbres individuals és que tendeixen a memoritzar les dades d'entrenament i fallen amb exemples nous.

El Random Forest soluciona aquesta limitació construint 200 arbres independents, cadascun entrenat amb una mostra aleatòria dels exemples i amb un subconjunt aleatori de variables en cada divisió. Gràcies a aquesta diversitat, cada arbre comet errors en llocs diferents, i la predicció final és la mitjana de les 200 prediccions individuals, cosa que cancel·la els errors individuals i dona un resultat molt més estable i generalitzable.

S'ha escollit aquest model perquè s'adapta bé a datasets de mida moderada, no requereix normalització de les variables, i ofereix automàticament la importància relativa de cada variable d'entrada, cosa que afegeix interpretabilitat al model. Amb 60 produccions sintètiques i ~18 blocs útils cadascuna s'obtenen ~1.080 exemples d'entrenament, un volum suficient per a un Random Forest però insuficient per a models més complexos que requereixen moltes més dades.

Durant la producció, el model rep les quatre variables del bloc actual i prediu directament Kp, Ki, Kd per al bloc següent, sense cap cerca en temps real. La variable més determinant és la tendència interna del bloc, seguida del pes mig i la desviació.

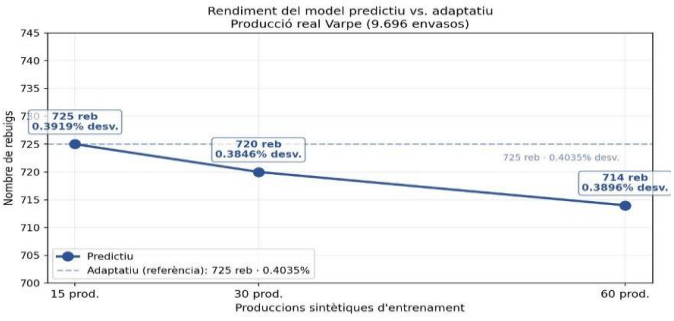

Figura 8. Rendiment del model predictiu segons el nombre de produccions per entrenar

Entrenat amb 60 produccions, el model obté 714 rebutjos sobre la producció real, superant l'adaptatiu (725) i mostrant una millora progressiva a mesura que augmenta el nombre de produccions d'entrenament.

5 RESULTATS

La següent recull els resultats principals de tots els mètodes sobre la producció real de Varpe (9.696 envasos, pes objectiu 47,0 g, original: 976 rebutjos).

Taula 2. Resultats dels diferents algorismes provats

Mètode	Rebutjos	% desv. pes mig
Original (sense PID)	976	0,87%
Grid search – mín. rebutjos (N=10)	716	0,408%
Grid search – equilibri (N=25)	800	0,265%
Grid search – mín. Desviació (N=75)	944	0,002%
Algorisme genètic (N=65)	714	0,347%
Algorisme adaptatiu W=2.000 (equilibri)	725	0,340%
Algorisme adaptatiu W=5.000 (mín. rebutjos)	694	0,461%
Algorisme predictiu	714	0,390%

Analitzant els resultats obtinguts, s'observen els comportaments dels diferents algorismes.

El grid search estableix la frontera de Pareto de referència i demostra que el trade-off és inherent al sistema: la configuració de mínims rebutjos (716 rebutjos) aconsegueix una reducció del 26,6% respecte a l'original, però a costa d'una desviació del pes mig de 0,408%; en canvi, la configuració de mínima desviació (944 rebutjos) aconsegueix un pes mig pràcticament exacte (0,002%) però redueix molt poc els rebutjos.

L'algorisme genètic supera el grid search en eficiència: explorant l'espai de manera autònoma, troba una configuració que no estava entre les 540 predefinides i obté 714 rebutjos mantenint una desviació raonable de 0,347%.

El PID adaptatiu demostra que adaptar els paràmetres al llarg de la producció té sentit: amb W=5.000, arriba als 694 rebutjos, la millor marca absoluta de tots els mètodes.

Finalment, el model predictiu amb machine learning [18], tot i treballar únicament amb produccions sintètiques, aconsegueix igualar el genètic amb 714 rebutjos sense necessitar cap cerca en temps real, i la seva tendència de millora amb més dades d'entrenament el converteix en el mètode amb més potencial de cara al futur.

Cal tenir en compte que aquests resultats corresponen a una producció concreta de la màquina de Varpe utilitzada com a referència. Tot i que el sistema és aplicable a màquines similars, cada envasadora té un comportament propi, els valors numèrics concrets i els resultats podrien variar en cas d'aplicar aquests mateixos algorismes.

5.1 Exercici: Impacte econòmic estimat

Per posar en perspectiva el valor pràctic d'aquestes millores, es planteja un exemple amb hipòtesis representatives del sector.

Una línia d'envasament industrial pot produir entre 2 i 3 milions d'envasos per dia. Prenent com a referència una instal·lació de 2,5 milions d'envasos diaris i un preu de cost per envàs de 1,20 €, es poden estimar dos tipus d'estalvi independents.

El primer és l'estalvi per reducció de rebutjos. Amb una taxa de rebuig base de l'1%, aquesta instal·lació genera 25.000 rebutjos per dia. Una reducció del 26,8%, com la obtinguda amb l'algorisme predictiu, suposaria evitar aproximadament 6.700 rebutjos diaris, equivalent a un estalvi d'uns 8.040 €/dia, és a dir, al voltant de 2,9 M€/any.

El segon és l'estalvi per reducció de la sobredosificació. Si el punt de partida fos una sobredosificació del 0,5% del pes mig, i es reduís fins al 0,39% com el cas on arriba el mateix algorisme predictiu, això representaria aproximadament 0,05 g estalviats per envàs. Amb el mateix material, això permet produir aproximadament 11 llaunes addicionals per cada 10.000 envasades, equivalent a unes 2.750 llaunes extra per dia i uns 3.300 €/dia, o al voltant d'1,2 M€/any.

Aquests exemples il·lustren com petits canvis en el control del pes poden suposar un impacte econòmic molt rellevant al llarg del temps, tant per la reducció de material rebutjat com per l'estalvi acumulat en sobredosificació.

6 Conclusions

Aquest treball ha desenvolupat, de manera progressiva i incremental, un sistema d'ajust intel·ligent dels paràmetres d'un controlador PID aplicat a una pesadora dinàmica industrial de Varpe. Cada fase ha construït sobre les bases de l'anterior, de manera que el valor aportat és acumulatiu i cada mètode implementat suposa un pas endavant respecte a l'anterior.

En primer lloc, s'ha implementat un simulador PID validat amb dades reals de producció, incorporant les particularitats del sistema: el treball per grups d'envasos, el retard de stock i el filtratge de feedback per ignorar anomalies puntuals. Aquest simulador ha estat la base sobre la qual s'han pogut provar i comparar tots els mètodes posteriors de manera rigorosa i reproductible.

A partir d'aquest simulador, l'exploració sistemàtica de l'espai de paràmetres mitjançant grid search ha permès identificar i quantificar el trade-off estructural del sistema: reduir rebutjos i reduir la desviació del pes mig són objectius en tensió, i la frontera de Pareto defineix les solucions on millorar un implica empitjorar l'altre. Aquesta frontera ha servit com a referència de comparació per a tots els mètodes posteriors.

L'algorisme genètic ha demostrat que és possible trobar configuracions òptimes de manera autònoma, sense explorar exhaustivament l'espai de cerca, i ha descobert valors de paràmetres que no estaven entre les opcions predefinides del grid search.

El PID adaptatiu ha anat un pas més enllà, ajustant els paràmetres bloc a bloc al llarg de la producció per adaptar-se a les variacions locals de la matèria prima i del comportament de la màquina, obtenint la millor marca absoluta en reducció de rebutjos.

Finalment, el model predictiu ha provat que és possible anticipar la configuració òptima del bloc següent a partir de l'historial après de produccions passades, en lloc de reaccionar al bloc anterior, i mostra una tendència clara de millora a mesura que s'incrementa el nombre de produccions d'entrenament.

Més enllà dels resultats numèrics, una de les conclusions més rellevants del treball és que no existeix una configuració universalment millor: la decisió de quina mètrica prioritzar depèn del context de cada client i de la matèria en qüestió. Si els rebutjos són destructius, és a dir que el producte no es pot recuperar ni reprocessar una vegada rebutjat, minimitzar-los seria clarament la prioritat. En canvi, si els rebutjos es poden reprocessar, pot tenir més sentit prioritzar la reducció de la sobredosificació i apropar el pes mig al nominal, recuperant material en cada envàs produït.

Agraïments

Vull agrair a Varpe Control de Peso S.A. per obrir les portes d'aquest projecte, per proporcionar dades reals de producció i per tot el suport tècnic rebut al llarg del desenvolupament. Treballar amb dades i context industrial real ha estat fonamental per donar sentit pràctic a cadascuna de les fases del treball.

Vull agrair també a tot l'equip de I+D de Varpe pel seu suport i els seus consells, i especialment al meu tutor Sergi Risueño per totes les indicacions, el seguiment i la disponibilitat al llarg de tot el procés, sobretot en els moments on calia prendre decisions sobre la direcció del projecte.

BIBLIOGRAFIA

[1] Real Decreto 1801/2008, de 3 de noviembre, por el que se establecen normas relativas a las cantidades nominales para productos envasados y al control de su contenido efectivo. Boletín Oficial del Estado, núm. 278 (2008). https://www.boe.es/buscar/pdf/2008/BOE-A-2008-17629-consolidado.pdf

[2] Pàgina oficial Varpe (2026). https://www.varpe.es/

[3] Åström, K.J. & Hägglund, T. (2006). Advanced PID Control. ISA – The Instrumentation, Systems, and Automation Society.

[4] PID Theory Explained (2025). National Instruments / NI. https://www.ni.com/es/shop/labview/pid-theory-explained.html

[5] PID Control Systems (2025). Siemens Digital Industries Software. https://plm.sw.siemens.com/

[6] GridSearchCV (2025) Scikit-learn Documentation. https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.GridSearchCV.html

[7] Tuning the hyper-parameters of an estimator (2025) Scikit-learn User Guide. https://scikit-learn.org/stable/modules/grid_search.html

[8] Deb, K. (2001). Multi-Objective Optimization using Evolutionary Algorithms. Wiley.

[9] [Multi-Objective Optimization and Pareto Front (2025). IBM. https://www.ibm.com/topics/multiobjective-optimization

[10] Pareto Front Visualization (2025). MathWorks Documentation. https://es.mathworks.com/help/gads/pareto-front.html

[11] Goldberg, D.E. (1989). Genetic Algorithms in Search, Optimization, and Machine Learning. Addison-Wesley.

[12] What are Genetic Algorithms? (2024). IBM. https://www.ibm.com/topics/genetic-algorithms

[13] Åström, K.J. & Wittenmark, B. (1995). Adaptive Control (2a ed.). Addison-Wesley.

[14] [32] Gain-Scheduled Control Systems (2025). MathWorks Documentation. https://www.mathworks.com/help/control/ug/gain-scheduled-control-systems.html

[15] Gain Scheduling for PID Controllers (2025). MathWorks. https://www.mathworks.com/help/slcontrol/ug/gain-scheduled-pid-controller.html

[16] Qué es un Random Forest? (2024). https://www.ibm.com/es-es/think/topics/random-forest

[17] Ensemble Methods and Random Forests (2025). Scikit-learn Documentation. https://scikit-learn.org/stable/modules/ensemble.html

[18] What is Machine Learning? (2024). IBM. https://www.ibm.com/topics/machine-learning

APÈNDIX

A1. GRÀFIQUES COMPLEMENTÀRIES RELACIONADES AMB ELS DIFERENTS MÈTODES I ALGORISMES

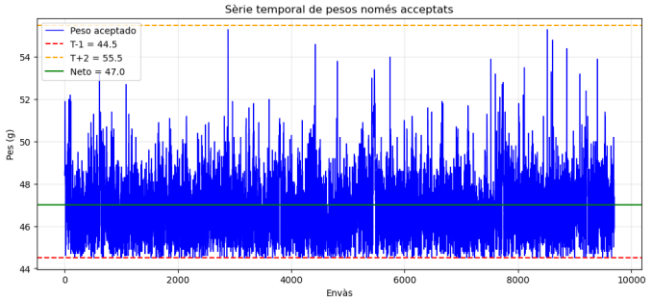

Figure 9. Anàlisi inicial: Sèrie temporal de pesos acceptats

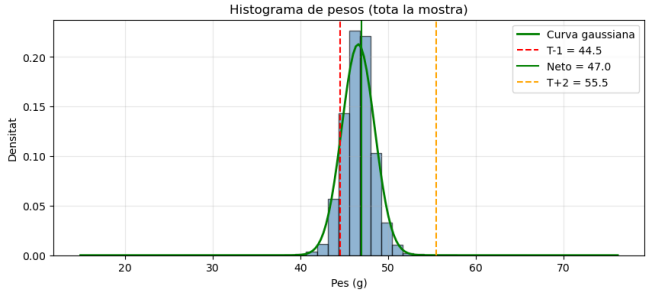

Figure 10. Anàlisi inicial: Histograma de tots els pesos

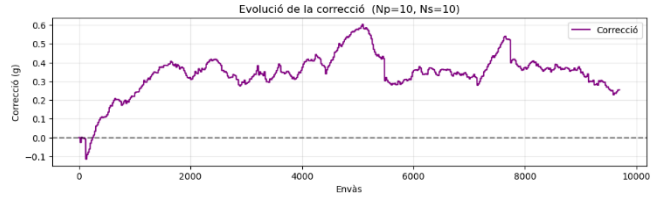

Figure 11. PID: Evolució de les correccions

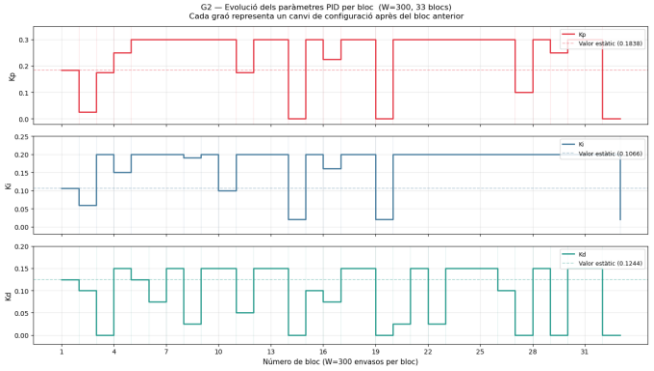

Figure 12. PID Adaptatiu: Canvis de paràmetres durant la producció