Uporaba planova pokusa u procesu poboljšanja kvalitete

Matić, Ivan

Master's thesis / Diplomski rad

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:235:962266

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb







SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Ivan Matić

Zagreb, 2021.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentor: Student:

Prof. dr. sc. Hrvoje Cajner Ivan Matić

Zagreb, 2021.

Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Zahvaljujem se mentoru prof.dr.sc. Hrvoju Cajner na pomoći i mentorstvu prilikom izrade ovog rada.

Ivan Matić

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE
Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za diplomske radove studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo materijala te mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum:	Prilog:
Klasa: 602-04/21-6/1	
Ur. broj: 15-1703-21	

DIPLOMSKI ZADATAK

Student: **IVAN MATIĆ** Mat. br.: 0035187567

Naslov rada na hrvatskom jeziku: **Uporaba planova pokusa u procesu poboljšavanja kvalitete**

Naslov rada na engleskom jeziku: **The use of design of experiments in process of quality improvement**

Opis zadatka:

Potreba za stalnom prilagodbom tržištu i održavanjem visoke razine konkurentnosti zahtijeva kontinuiranu promjenu i poboljšanje proizvoda i procesa. Svaka promjena donosi i određeni rizik. Smanjenje mogućih posljedica ostvaruje se kontinuiranim praćenjem kvalitete procesa služeći se metodama statističke kontrole procesa, a jedan od efikasnih alata jest i uporaba planova pokusa. Korištenjem planova pokusa postižu se velike uštede u resursima pri analizi uzročno posljedičnih veza te se osigurava da su proizvodi i procesi sukladni i da zadovoljavaju ako ne i premašuju propisane standarde kvalitete.
U diplomskom radu potrebno je:
1. Detaljno opisati teorijske osnove planova pokusa.
2. Skicirati podjelu planova pokusa i detaljno ih sistematizirati.
3. Dati presjek najčešće korištenih modela planova pokusa u procesu poboljšavanja kvalitete.
4. Analizirati primjere dobre prakse te koristeći se dostupnim programskim paketima prikazati primjere iz recentnijih literaturnih izvora.
5. Razraditi koncept primjene metode planova pokusa za odabrani problem iz prakse.
U radu je potrebno navesti korištenu literaturu te eventualno dobivenu pomoć.

Zadatak zadan: 30. travnja 2020.

Rok predaje rada: 8. srpnja 2021.

Predviđeni datum obrane: 12. srpnja do 16. srpnja 2021.

Zadatak zadao: prof. dr. sc. Hrvoje Cajner

Predsjednica Povjerenstva: prof. dr. sc. Biserka Runje

SADRŽAJ

SADRŽAJ I
POPIS SLIKA IV
POPIS TABLICA VI
POPIS OZNAKA VIII
POPIS KRATICA IX
SAŽETAK X
SUMMARY XI
1. UVOD 1
1.1. Smjernice za planiranje pokusa 3
1.1.1. Prepoznavanje problema 3
1.1.2. Odabir odzivne varijable 4
1.1.3. Izbog faktora, razine i raspona 4
1.1.4. Izbor plana pokusa 5
1.1.5. Provođenje pokusa 6
1.1.6. Statistička analiza podataka 6
1.1.7. Zaključak i preporuke 6
1.2. Povijest planiranja pokusa 7
1.3. Temeljna načela planiranja pokusa 8
1.3.1. Randomizacija 8
1.3.2. Replikacija 8
1.3.3. Blokiranje 9
2. KLASIFIKACIJA PLANA POKUSA 10
2.1. Općenita klasifikacija 10
2.1.1. Broj proučavanih faktora 10
2.1.2. Ograničenja izvedbe 10
2.1.3. Cilj pokusa 11
2.1.4. Pionir pristupa 12
2.2. Klasifikacija plana pokusa prema redu modela 13
2.3. Faktorski plan pokusa na dvije razine - 2^k 13
2.3.1. Faktorski plan pokusa - 2^2 13

2.4. Djelomični faktorski plan pokusa - 2^{k-p} 15
2.4.1. Osnovni princip 15
2.4.2. Rezolucija dizajna 17
2.5. Plackett-Burman dizajn - PB 17
2.6. Metode odzivnih površina - RSM 18
2.6.1. Sekvencijalnost eksperimenta 19
2.6.2. Metoda strmog uspona 20
2.7. Plan pokusa za podešavanje odzivne površine drugog reda 20
2.7.1. Faktorski plan pokusa na tri razine - 3^k 20
2.7.2. Centralno kompozitni plan - CCD 21
2.7.3. Box -Behnken plan pokusa - BBD 22
2.8. Pokusi sa smjesama 23
2.8.1. Kanonski polinomi za pokuse sa smjesama 24
2.8.2. Model elementarne rešetke - Simplex lattice 25
2.8.3. Elementarni model s težištem - Simplex centroid 25
2.8.4. Pokusi sa smjesama sa ograničenjima 25
2.8.5. Pokusi sa smjesama s procesnim varijablama 27
2.9. Taguchi metoda 28
3. NAJČEŠĆE KORIŠTENI MODELI PLANOVA POKUSA U PROCESU POBOLJŠANJA KVALITETE 32
4. ANALIZA PRIMJERA DOBRE PRAKSE 35
4.1. Primjer djelomičnog plana pokusa: Modeliranje aditivnog 3D printanja baziranog na metodologiji planiranja pokusa 35
4.1.1. Analiza utjecaja na čvrstoću 37
4.1.2. Analiza utjecaja na Youngov modul 42
4.2. Primjer metode odzivne površine: Poboljšanje kvalitete terminala slušalice pomoću sekvencijalnog plana pokusa 46
4.3. Primjer Taguchijevog plana pokusa: Poboljšanje kvalitete površine strojne obrade saće aluminija postupkom fiksiranja ledom 50
5. EKSPERIMENTALNI DIO 53
5.1. Analiza odziva volumena punjenja 55
5.2. Analiza ciklusa 58
5.3. Optimizacija 61
5.4. Post analiza 62

6. ZAKLJUČAK....64
LITERATURA....65

POPIS SLIKA

Slika 1. Opći model procesa 1
Slika 2. OFAT pristup s tri faktora 2
Slika 3. Primjer plana pokusa s tri faktora 2
Slika 4. Općenita klasifikacija plana pokusa 10
Slika 5. Klasifikacija plana pokusa prema redu modela 13
Slika 6. Grafički prikaz 2^2 faktorskog plana pokusa 14
Slika 7. a) Odziv faktora A bez međudjelovanja faktora B, b) sa međudjelovanjem faktora B 15
Slika 8. Djelomični faktorski plan pokusa 16
Slika 9. Prikaz kontura dijagrama odzivne površine 18
Slika 10. Sekvencijalnost modela odzivnih površina 19
Slika 11. Metoda strmog uspona 20
Slika 12. Kombinacije faktora u 3^2 dizajnu 21
Slika 13. Konstrukcija centralno kompozitnog plana 21
Slika 14. Različite strukture CCD: plošno centriran (CCF), upisan (CCI) i opisan(CCC) 22
Slika 15. Box-Benken dizajn za 3 faktora i jednom centralnom točkom 23
Slika 16. Ograničeni faktorski prostor za smjese s a) 2 komponente i b) 3 komponente 24
Slika 17. Transformacija L-pseudo komponenta 26
Slika 18. Transformacija U-pseudo komponenta 27
Slika 19. Elementarni model s težištem na svakoj točki fakorskog plana pokusa 2^3 (a) 2^3 Faktorski plan pokusa na svakoj točki elementarnog modela s težištem (b) 28
Slika 20. Tradicionalni pristup definicije kvalitete 28
Slika 21. Taguchijev pristup definicije kvalitete 29
Slika 22. Graf prikaz raspodjele plana pokusa 32
Slika 23. Model procesa 3D printanja 35
Slika 24. Pareto dijagram za opterećenje pucanja 37
Slika 25. Normalizirani papir za opterećenje pucanja 37
Slika 26. Normalizirani papir vjerojatnosti ostataka a) i Box Cox dijagram b) 40
Slika 27. a) Slučajno rasipanje ostataka u odnosu na predviđene vrijednosti za rezultate, b) slučajno rasipanje ostataka u odnosu na redoslijed izvođenja pokusa 41

Slika 28. Grafički prikaz međudjelovanja faktora D i E na opterećenje pucanja.....41
Slika 29. a) Pareto dijagram b) normalizirani papir za Youngov modul 42
Slika 30. Box-Cox dijagram.....43
Slika 31. a) Normalizirani papir vjerojatnosti ostataka, b) slučajno rasipanje ostataka u odnosu na (predviđene)vrijednosti za rezultate, c) slučajno rasipanje ostataka u odnosu na redoslijed izvođenja pokusa 45
Slika 32. Grafički prikaz međudjelovanja faktora D i C na Youngov modul za a) horizontalnu, b) vertikalnu poziciju cijevi.....45
Slika 33. Model procesa terminala slušalice 46
Slika 34. Članovi koji ulaze u model 47
Slika 35. a) Normaliziranim papirom vjerojatnosti ostataka, b) slučajno rasipanje ostataka u odnosu na modelom izračunate vrijednosti, c) slučajno rasipanje ostataka u odnosu na redoslijed izvođenja pokusa 49
Slika 36. a) Konturni dijagram, b) 3D prikaz odzivne površine.....49
Slika 37. Model procesa strojne obrade saća.....50
Slika 38. a) Dijagram glavnih efekata za srednju vrijednost, b) omjer signal šum 52
Slika 39. Linija za poluatomatsko punjenje 53
Slika 40. Model procesa punjenja spremnika.....53
Slika 41. Članovi modela 56
Slika 42. a) Normaliziranim papirom vjerojatnosti ostataka, b) slučajno rasipanje ostataka u odnosu na modelom izračunate vrijednosti, c) Slučajno rasipanje ostataka u odnosu na redoslijed izvođenja pokusa 57
Slika 43. a) Konturni dijagram b)3D prikaz odzivne površine 58
Slika 44. Članovi modela 58
Slika 45. a) Normaliziranim papirom vjerojatnosti ostataka, b) slučajno rasipanje ostataka u odnosu na modelom izračunate vrijednosti, c) slučajno rasipanje ostataka u odnosu na redoslijed izvođenja pokusa 60
Slika 46 a) Konturni dijagram b)3D prikaz odzivne površine 60
Slika 47. „Ramp“ prikaz.....61
Slika 48. Rezultat numeričke optimizacije u 2D (a) i 3D (b) prikazu 62

POPIS TABLICA

Tablica 1. Faktorski plan pokusa 2^2 14
Tablica 2. Djelomični faktorski plan pokusa 15
Tablica 3. Primjer izvedbe centralno kompozitnog plana sa 3 faktora 22
Tablica 4. Ortogonalni niz 30
Tablica 5. $L_8(2^7)$ ortogonalni niz 30
Tablica 6. Popis znanstvenih članaka 32
Tablica 7. Razine faktora procesa 3D printanja 35
Tablica 8. Rezultantna matrica sa odzivima 36
Tablica 9. Rezultati analize varijance 38
Tablica 10. Statistički paarametri modela 38
Tablica 11. Koeficijenti u kodiranim vrijednostima faktora 39
Tablica 12. Rezultati analize varijance 42
Tablica 13. Statistički parametri modela 43
Tablica 14. Rezultati analize varijance 44
Tablica 15. Statistički parametri modela 44
Tablica 16. Faktori i njihove razine procesa terminala slušalice 46
Tablica 17. Vrijednosti faktora te izmjerene vrijednosti komplanarnosti 46
Tablica 18. Tablica analize varijance 47
Tablica 19. Statistički parametri modela 48
Tablica 20. Koeficijenti u kodiranim faktorima 48
Tablica 21. Razine i vrijednosti faktora u procesu strojne obrade saća 50
Tablica 22. Taguchijev L_{16} ortogononalni pokus 50
Tablica 23. Taguchijev L_{16} ortogononalni pokus sa odzivom i S/N omjerom 51
Tablica 24. Odziv signal-šum 52
Tablica 25. Faktori i njihove razine 54
Tablica 26. Rezultantna matrica s odzivima volumenom i trajanjem ciklusa 54
Tablica 27. Sažetak prikladnosti modela 55
Tablica 28. Rezultati analize varijance 56
Tablica 29. Statistički parametri modela 57
Tablica 30. Sažetak prikladnosti modela 58

Tablica 31. Rezultati analize varijance 59
Tablica 32. Statistički parametri modela 59
Tablica 33. Sažetak kriterija optimizacije 61
Tablica 34. Optimalna vrijednost za zadane uvjete 62
Tablica 35. Izvedba konfirmacijskih pokusa 63
Tablica 36. Podaci potvrde 63

POPIS OZNAKA

Oznaka	Mjerna jedinica	Opis oznake
E		očekivani odziv
k		broj faktora
K		konstanta ovisna o strukturi troškova gubitka
l_i		donje ograničenje proporcije smijese
L		gubitak
m		ciljana vrijednost
M		broj točaka u modelu
N		broj pokusa
n_c		broj centralnih točaka
s^2		varijanca
q		broj sastojaka smjese
u_i		gornje ograničenje proporcije smjese
x		faktori
X		vrijednost značajke kvalitete
y		odziv
α		udaljenost aksijalne točke od središta dizajna
β		nepoznati faktori
ε		slučajna pogreška
η		odzivna površina

POPIS KRATICA

Kratica	**Opis**
ANOVA	*Analysis of Variance* - analiza varijance
CCD	*Central Composite Design* - Centralno kompozitni plan
DMAIC	*Define Measure Analyse Improve Control* - Definiranje Mjerenje Ananliziranje Poboljšanje Kontrola
DOE	*Design of Experiments* - planiranje pokusa
FDM	*Fusion Deposition Modeling* - modeliranje topljenog taloženja
OA	*Orthogonal array* - ortogonalni niz
OFAT	*One factor at a time* - faktorpo faktor
RSM	*Response surface methodology* - metoda odzivne površine
SPC	*Statistical process control* - statistička kontrola procesa

SAŽETAK

Tema ovog rada je „Uporaba planova pokusa u procesu poboljšanja kvalitete“. U radu je detaljno razrađeno planiranje pokusa. U prvom dijelu rada opisane su teorijske osnove plana pokusa. Opisana je kratka povijest planova pokusa, smjernice za planiranje pokusa i temeljna načela planova pokusa. U drugom dijelu rada detaljno je sistematizirana podjela planova pokusa. Prikazan je kratki opis najčešćih statističkih metoda. Opisani su faktorski planovi pokusa, metoda odzivne površine, te Taguchijeva metoda. U trećem dijelu rada pomoću baze članaka Scopus prikazan je presjek najčešće korištenih modela planova pokusa u procesu poboljšanja kvalitete. Iz te baze su u četvrtom dijelu rada analizirani primjeri za svaku od metoda pomoću programskih paketa. U petom dijelu rada proveden je eksperimentalni dio rada u kojem se optimizirala linija za punjenje spremnika aditivom za motorna vozila.

Ključne riječi: Plan pokusa, Faktorski plan pokusa, Metoda odzivne površine, Taguchijeva metoda, Optimiziranje

SUMMARY

The topic of this paper is „The use of design of experiments in process of quality improvement“. This paper in detail elaborates design of experiments. The first part of the paper describes the theoretical foundations of the design of experiments. A brief history of experimental design, guidelines for designing experiments and basic principles of experimental design are described. In the second part a detailed systematization of design of experiments division is given. A brief description of the most common statistical methods is presented. Factorial designs, Response surface designs and Taguchi method is described. In the third part of the paper, using the Scopus article database, a cross-section of the most frequently used experimental designs in the process of quality improvement is presented. From this database, in the fourth part of the paper, examples for each of the methods were analyzed using software packages. The fifth part of the paper presents the experimental part in which a additive for motor vehicles tank filling line was optimized.

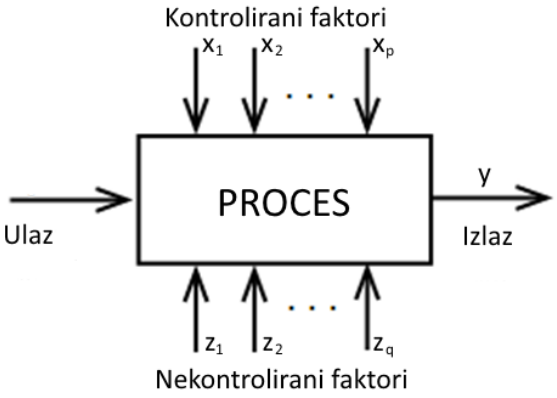
Key words: Design of experiments, Factorial designs, Response surface methodology, Taguchi design, Optimization

1. UVOD

Planiranje pokusa (eng. Design of experiments, DOE) je metoda koja se koristi za planiranje i provođenje eksperimenata, kao i za analizu i interpretaciju podataka dobivenih eksperimentima. Može se definirati kao niz testova u kojima se vrše namjerne promjene na ulaznim faktorima procesa ili sustava kako bi se mogli promatrati i identificirati razlozi promjena u izlaznim rezultatima.

Pokušavamo koristiti eksperimentiranje kako bismo smanjili vrijeme za dizajn i razvoj novih proizvoda i procesa, poboljšali rad postojećih procesa, poboljšali pouzdanost i performanse proizvoda, postigli robusnost proizvoda i procesa, izvodili procjenu materijala, alternativnih dizajna i tolerancija sustava.

Dobro dizajniran eksperiment je važan segment jer rezultati i zaključci koji se mogu izvesti iz eksperimenta u velikoj mjeri ovise o načinu prikupljanja podataka. Općenito se eksperimenti koriste za proučavanje performansi procesa i sustava. Proces ili sustav možemo prikazati modelom prikazanim slikom (Slika 1). Karakteriziramo ga pomoću nezavisnih ulaznih varijabla, koje mogu biti nekontrolirane i kontrolirane, te zavisnih izlaznih varijabli koje nazivamo odzivi procesa.



Slika 1. Opći model procesa

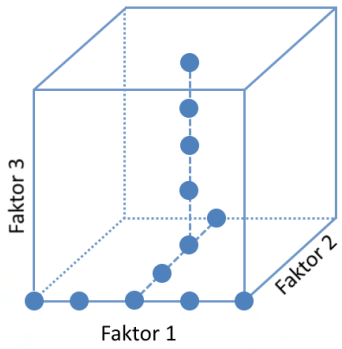
Neke od procesnih varijabla i svojstva materijala mogu se kontrolirati, dok su druge varijable, poput okolišnih čimbenika ili nekih svojstava materijala, nekontrolirane.

Ciljevi pokusa mogu uključivati sljedeće [1]:

- Utvrđivanje varijabli koje najviše utječu na izlazni rezultat y

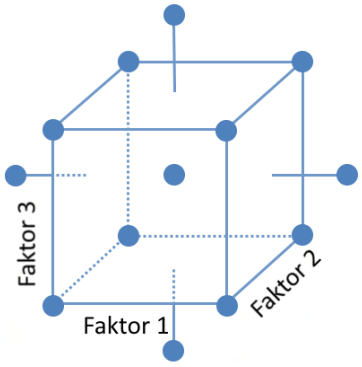
- Određivanje postavke utjecajnih x-ova tako da je y gotovo uvijek blizu željene nazivne vrijednosti
- Određivanje kako postaviti utjecajne x-ove tako da je varijabilnost y što manja
- Određivanje kako postaviti utjecajne x-ove tako da su učinci nekontroliranih varijabli svedeni na minimum

Faktor po faktor pristup (eng. one-factor-at-a-time, OFAT) se sastoji od odabira početne točke za svaki faktor te zatim variranja svakog faktora preko njegovog raspona dok ostale faktore držimo konstantnim (Slika 2).



Slika 2. OFAT pristup s tri faktora

Ako se teoretski maksimalni prinos pojavi na točci izvan potpuno ćemo ga promašiti. Moramo imati određene sreće da „pogodimo“ optimum uz pretpostavku da u pokusu nisu prisutne nikakve interakcije faktora ili nelinearna ponašanja. Prikaz plana pokusa za maksimiziranje prinosa mijenjanjem tri faktora prikazan je na slici 3.



Slika 3. Primjer plana pokusa s tri faktora

U slučaju da se točka pokusa pojavi na točci na kojoj nismo proveli eksperiment možemo napraviti statistički model koji koristi točke da estimira prinos na točkama na kojima nismo proveli eksperiment.

1.1. Smjernice za planiranje pokusa

Opći koraci i smjernice za planiranje i provođenje planova pokusa opisani su u nastavku [1]:

1.1.1. Prepoznavanje problema

Potrebno je definirati sve ideje o ciljevima pokusa. Potrebno je tražiti informacije od svih nadležnih strana: inženjering, osiguranje kvalitete, proizvodnja, marketing, menadžment, kupac i operativno osoblje (koji obično imaju puno uvida i koji se često ignoriraju). Zbog tog razloga se preporučuje timski pristup planiranju pokusa. Također važno je imati na umu opće ciljeve pokusa. Postoji nekoliko razloga za provođenje pokusa i svaka vrsta pokusa stvorit će vlastiti popis specifičnih pitanja koja je potrebno riješiti .

Neki od razloga za provođenje pokusa uključuju:

- Karakterizacija i odabir faktora - Kad je sustav ili proces nov, obično je važno odrediti koji faktori imaju najviše utjecaja na odzive koji nas zanimaju. Obično ima puno faktora što ukazuje da provoditelji pokusa nemaju dobar uvid o sistemu. Potrebno je odabrati faktore (eng. screening) kako bi dobili željene performanse iz sustava.
- Optimizacija pokusa - Nakon što je sustav karakteriziran i sigurni smo da su identificirani važni faktori, sljedeći cilj je obično optimizacija, odnosno pronalaženje postavki ili razina važnih faktora koji rezultiraju poželjnim odzivima.
- Potvrđivanje pokusa - U pokusu potvrđivanja (eng. Confirmation experiment), provoditelja pokusa pokušava provjeriti djeluje li ili se ponaša sustav na način koji je u skladu s nekom teorijom ili prošlim iskustvom.
- Pokus otkrića - Sa pokusima otkrića (eng. Discovery experiment) provoditelji pokusa pokušavaju utvrditi što se događa kada istražujemo nove materijale, nove faktore ili nove domene faktora.
- Robusnost - Ovi pokusi se bave pitanjem pod kojim uvjetima varijable odziva interesa ozbiljno propadaju ili koji bi uvjeti doveli do neprihvatljive varijabilnosti u varijablama odziva. Određujemo kako možemo postaviti faktore u sustavu koje možemo kontrolirati kako bi minimizirali varijabilnost koja se prenosi u odziv od faktora koje ne možemo dobro kontrolirati.

Važan aspekt formuliranja problema je prepoznavanje da jedan sveobuhvatni pokus neće odgovoriti na sva pitanja na zadovoljavajući način. Za sveobuhvatni pokus provoditelja pokusa mora imati znanje da odgovori točno na više pitanja, inače će dobiveni rezultati biti razočaravajući. Sekvencijski pristup pri kojem se koristi niz manjih pokusa, od kojih svaki ima određeni cilj je bolja strategija.

1.1.2. Odabir odzivne varijable

Odabirom odzivne varijable, provoditelja pokusa treba biti siguran da ta varijabla stvarno pruža korisne informacije o procesu koji se proučava. Najčešće će prosječno ili standardno odstupanje (ili oboje) izmjerene karakteristike biti varijabla odziva. Provoditelji pokusa moraju odlučiti kako će se mjeriti svaki odziv i baviti se pitanjima kao što su kako će biti kalibrirani mjerni sustav i kako će ta kalibracija biti održavana tijekom pokusa. Mogućnost mjernog sustava (ili pogreška mjerenja) je važan čimbenik.

1.1.3. Izbor faktora, razine i raspona

Uzimajući u obzir faktore koji mogu utjecati na rad nekog procesa ili sustava, provoditelj pokusa obično otkriva da se ti faktori mogu klasificirati kao potencijalni faktori pokusa ili nepoželjni faktori (eng. nuisance factors). Potencijalni faktori pokusa su oni faktori koje provoditelj pokusa želi varirati u pokusu. Nepoželjni faktori mogu imati velike učinke koje moramo uzeti u obzir, ali možda nas neće interesirati u kontekstu provođenog pokusa. Nepoželjne faktore možemo klasificirati kao faktore koje možemo kontrolirati, faktore koje ne možemo kontrolirati i faktore šuma. Nepoželjni faktori koje možemo kontrolirati su oni čije razine može provoditelj pokusa postaviti. Princip blokiranje je koristan pri suočavanju sa njima. Za nepoželjne faktore koji se ne mogu kontrolirati, ali se mogu mjeriti, koristi se analiza kovarijance za kompenzaciju njihovih efekta.

Kad faktor koji prirodno i nekontrolirano varira u procesu, a može se kontrolirati u svrhu pokusa, često ga nazivamo faktorom šuma. U takvim je situacijama naš cilj obično pronaći postavke upravljivih faktora pokusa koji umanjuju varijabilnost koja se prenosi od faktora šuma. To se naziva i studija robusnosti procesa ili robusni problem pokusa. Nakon odabira faktora moramo odabrati regiju interesa za svaki faktor (raspon u kojem će ti faktori varirati) i specifične razine na kojima će se izvoditi faktori. Za to je potrebno znanje procesa. To je obično kombinacija praktičnog iskustva i teorijskog razumijevanja procesa.

Kada je cilj eksperimenta probiranje faktora ili karakterizacija procesa, obično je najbolje držati razine faktora niskim. Dijagram uzroka i posljedica (eng. cause-and-effect diagram) može biti korisna tehnika organiziranja nekih od podataka prikupljenih u pred planiranju pokusa. Dijagram uzroka i posljedica poznat je i kao dijagram riblje kosti (eng. fishbone diagram) jer se "efekt" od interesa ili varijabla odziva crta duž kralježnice dijagrama, a potencijalni uzroci ili faktori organizirani su u nizu rebara.

1.1.4. Izbor plana pokusa

Izbor dizajna uzima u obzir broj uzorka (broj replikacija), odabir prikladnog redoslijeda ispitivanja pokusa i odluku da li je potrebno blokiranje ili randomizacijska ograničenja. Odabir plana pokusa također uključuje i odabir empirijskog modela za opisivanje rezultata. Model je kvantitativni odnos između odziva i važnih faktora pokusa. Za mnoge će slučajeve biti prikladan polinomni model niskog reda. Model prvog reda sa dvije varijable je (1):

$$y = \beta_0 + \beta_1 x + \beta_2 x + \varepsilon \quad \textbf{(1)}$$

Gdje je

y	odziv
x	faktori
β	nepoznati faktori
ε	slučajna pogreška

Nepoznati parametri β procjenjujemo na osnovu podataka pokusa, a slučajna pogreška ε koja objašnjava pogrešku pokusa u sustavu koji se proučava. Model prvog reda često nazivamo i modelom glavnih učinaka (eng. main effects model). Modeli prvog reda se intenzivno koriste u pokusima karakterizacije i probiranje faktora. Uobičajeno proširenje modela prvog reda dobiva se dodavanjem interakcije (2):

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_{12} x_1 x_2 + \varepsilon \quad \textbf{(2)}$$

gdje produkt x_1x_2 predstavlja interakciju između dva faktora pokusa. Budući da su interakcije među faktorima relativno česte, model prvog reda s interakcijama se široko koristi.

Drugi korišteni model je model drugog reda (3):

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_{12} x_1 x_2 + \beta_{11} x_1^2 + \beta_{22} x_2^2 + \varepsilon \quad \textbf{(3)}$$

Modeli drugog reda često se koriste u pokusima optimizacije.

1.1.5. Provođenje pokusa

Pokusi se provode pomoću matrice pokusa (eng. design matrix). Prilikom izvođenja pokusa, izuzetno je važno pažljivo nadzirati proces kako bismo osigurali da se sve odvija prema planu. Pogreške eksperimentalnog postupka u ovoj fazi obično poništavaju valjanost eksperimenta. Neki sugeriraju da se prije glavnog izvođenja pokusa nekoliko probnih izvedba provede. Te izvedbe daju informacije o dosljednosti eksperimentalnog materijala, provjeru mjernog sustava i grubu ideju eksperimentalne pogreške.

1.1.6. Statistička analiza podataka

Za analizu podataka treba koristiti statističke metode kako bi rezultati i zaključci bili objektivni. Jednostavne grafičke metode igraju važnu ulogu u analizi i interpretaciji podataka. Budući da se mnoga pitanja na koja provoditelj pokusa želi odgovoriti mogu postaviti u okvir ispitivanja hipoteze. Testiranje hipoteza i postupak procjene intervala pouzdanosti vrlo su korisni u analizi podataka iz planiranog pokusa.

1.1.7. Zaključak i preporuke

Nakon što se analiziraju podaci, provoditelj pokusa mora izvesti praktične zaključke o rezultatima i preporučiti sljedeće aktivnosti. Grafičke metode se često korisne u ovoj fazi, posebno u prezentiranju rezultata drugima. Naknadne izvedbe i ispitivanje radi potvrde se mogu provesti kako bi dobili zaključke iz pokusa. Planiranje pokusa je iterativno. Obično je velika pogreška dizajnirati jedan, veliki, sveobuhvatni pokus na početku studije. Uspješan pokus zahtijeva znanje o važnim faktorima, rasponima u kojima se ti faktori trebaju mijenjati, odgovarajućem broju razina faktora koje se koriste i odgovarajućim mjernim jedinicama za ove varijable. Općenito, ne znamo savršene odgovore na ta pitanja, ali učimo o njima provođenjem pokusa. Kako napreduje program plana pokusa, često uklanjamo neke ulazne varijable, a dodajemo druge, mijenjamo područje istraživanja za neke faktore ili dodamo nove varijable odziva. Prema tome, obično provodimo planiranje pokusa sekvencijalno, i po pravilu bi u prvi pokus trebalo uložiti najviše oko 25 posto raspoloživih resursa.

1.2. Povijest planiranja pokusa

Povijest planiranja pokusa se može podijeliti u pet razdoblja razvoja. Prva era razvila se u poljoprivrednoj djelatnosti pionirskim radom Sir Ronalda A. Fishera u 1920-ima i ranim 1930-ima. Fisher je otkrio da je nepravilno provođenje eksperimenata ometalo analizu podataka. Zbog prirode poljoprivrede, pokusi su bili veliki pa je bilo potrebno dugo vremena za njihovo provođenje te su bili podložni različitim izvorima varijacije. Zbog tih je svojstva Fisher kroz interakciju sa znanstvenicima i istraživačima u raznim područjima koncepte randomizacije, replikacije i blokiranja. Fisher je sustavno uveo statistička razmišljanja i načela u postupak planiranja pokusa, uključujući koncepte faktorskog pokusa i analize varijance (ANOVA) [1].

Iako primjena statističkim metoda u industrijskom okruženju započela već u 1930-ima, drugo, ili industrijsko, razdoblje počelo je razvojem Box i Wilsonove metode odzivne površine (eng. response surface methology, RSM) u kemijskog industriji 1951-e godine. Otkrili su da nove tehnike moraju biti razvijene sa dva jedinstvena obilježja za razliku od pokusa u poljoprivrednoj djelatnosti, neposrednost i sekvencijalnost. Neposrednost se odnosi na činjenicu da se odzivna varijabla može promatrati gotovo odmah, sekvencijalnost se odnosi na sposobnost brzog učenja ključnih informacija iz male skupine izvedba, koja se može koristit za planiranje sljedećeg pokusa. Međutim primjena statističkog dizajna na razini postrojenja ili proizvodnog procesa još nije bila raširena zbog nedovoljne izobrazbe u osnovnim statističkim konceptima i metodama inženjera, i nedostatak računalnih resursa i softvera kako bi se poduprla primjena statističkih planova pokusa. U ovoj eri počeo je rad na optimalnim planovima pokusa. Taj pristup nije našao veliki broj primjene zbog nedostatka računalnih alata za njihovu provedbu [1].

Treće razdoblje započinje krajem 1970-ih zbog sve većeg interesa zapadne industrije za poboljšanje kvalitete. Na čelu je bio Genichi Taguchi koji se zalagao za upotrebu planiranih pokusa koje je nazvao robusni parametar dizajn (RPD), stvaranje pokusa neosjetljivim na okolišne faktore ili druge faktore koje je teško kontrolirati. Taguchi je predložio visoko djelomične planove pokusa i ortogonalne nizove (eng. orthogonal array,OA) za rješavanje tih problema. Dobivena metodologija izazvala je mnogo rasprava i kontroverzi. Iako su Taguchijevi inženjerski koncepti i ciljevi utemeljeni , postajali su znatni problemi sa njegovom eksperimentalnom strategijom i metodama analize podataka [1].

Jedan od pozitivnih rezultata Taguchijevog pristupa bio je početak četvrtog razdoblja statističkog planiranja pokusa. Rasprava o učinkovitosti Taguchijevih metoda analize i dizajna dovela je do obnavljanja interesa u DOE i razvoja mnogih novih korisnih pristupa kako bi se Taguchijeva filozofija smanjenja varijance i robusnost dovela u akciju na efikasan i učinkovit način. U ovom razdoblju računalni softver za izgradnju i vrednovanje pokusa se uvelike poboljšao s mnogim novim značajkama i mogućnostima [1].

Peto razdoblje povezano je sa pojavom Šest Sigma kvalitetne inicijative. DOE se smatra važnom tehnikom u Šest Sigma zbog mogućnosti ispitivanja potencijalnih uzroka varijacije. Koristi se u fazi poboljšanja metode Definiranje - Mjerenje - Analiziranje - Poboljšanje - Kontrola (eng. Define-Measure-Analyse-Improve-Control, DMAIC) [2].

1.3. Temeljna načela planiranja pokusa

1.3.1. Randomizacija

Korištenje statističkih metoda zahtijeva primjenu randomizacije (slučajni raspored) u pokusu. Raspodjela uzoraka za provođenje pokusa kao i redoslijed pokusa treba biti slučajan. Statističke metode zahtijevaju da su opažanja (ili greške) neovisno raspoređene slučajne varijable. Također pomaže u usrednjavanju učinaka stranih čimbenika koji mogu biti prisutni tijekom provođenja pokusa [1].

1.3.2. Replikacija

Pod replikacijom podrazumijevamo neovisno ponavljanje svake kombinacije faktora. Replikacija ima dva važna svojstva. Prvo, eksperimentu omogućuje procjenu pogreške eksperimenta. Ova procjena pogreške postaje osnova za utvrđivanje jesu li promatrane razlike u podacima statistički različite. Drugo, ako je srednja vrijednost uzorka korištena za procjenu stvarne srednje vrijednosti razine faktora u pokusu, replikacija dopušta da provoditelj pokusa dobije precizniju procjenu ovog parametra. Postoji razlika između repliciranja i repeticije mjerenja. Repliciranjem potencijalno možemo odrediti izvor varijabilnosti i između pokusa i unutar pokusa. Replikacija reflektira izvore varijabilnosti između izvođenja i (potencijalno) unutar izvođenja [1].

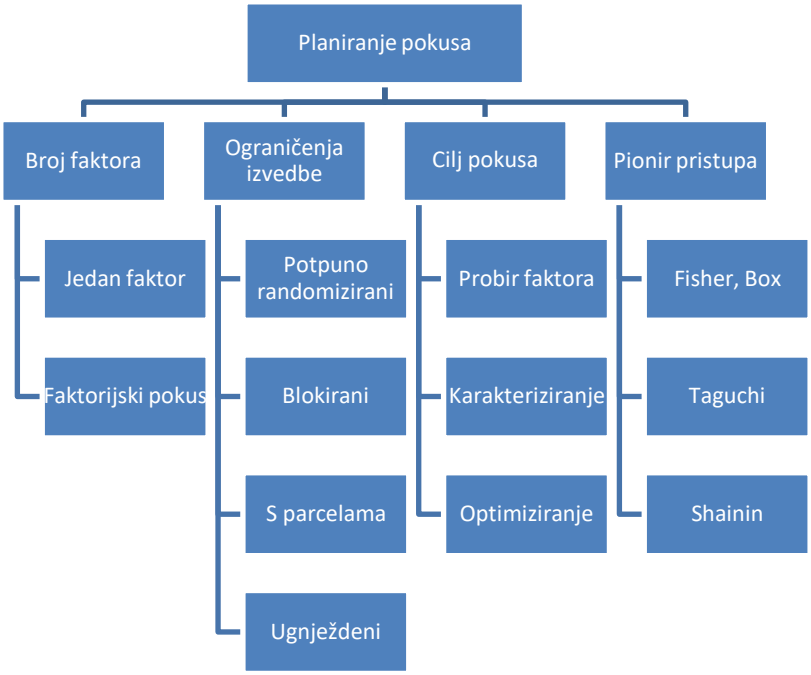
1.3.3. Blokiranje

Blokiranje koristi se za poboljšanje preciznosti kojom se uspoređuju faktori koji su od interesa. Često se blokiranje koristi kako bi se smanjila ili uklonila varijabilnost koja se prenosi od nepoželjnih faktora, faktora koji mogu utjecati na odziv pokusa, ali koje nas direktno ne zanimaju. Tipični nepoželjni faktori su serije sirovina za proizvodnu situaciju, različiti operatori, radnici ili predmeti ispitivanja, dijelovi opreme za ispitivanje. Kada se proučava proces te vrijeme (smjene, dani, itd.) mogu biti faktor koji utječe na odziv. Općenito, blok je skup relativno homogenih eksperimentalnih uvjeta [1].

2. KLASIFIKACIJA PLANA POKUSA

2.1. Općenita klasifikacija

Postoji nekoliko načina da se klasificiraju vrste DOE-a [2]. U nastavku je opisana općenita klasifikacija (Slika 4).



Slika 4. Općenita klasifikacija plana pokusa

2.1.1. Broj proučavanih faktora

Jedan faktor uključuje proučavanje jednog faktora samo na dvije ili više razina. Cilj je obično usporediti te razine i pronaći najbolje u odnosu na određenu mjeru. Faktorski pokus dva ili više faktora variraju se istodobno. Učinkovitija je alternativa pokusima s jednim faktorom, jer zahtijeva manje izvođenja i omogućuje procjenu interakcija faktora. Kada se koriste faktori s različitim brojem razina, pokus se naziva mješovitim pokusom.

2.1.2. Ograničenja izvedbe

Planovi se mogu razvrstati u potpuno randomizirane (eng. completely randomised), blokirane (eng. blocked), planove s parcelama (eng. split-plot) ili ugnježđene (eng. nested), ovisno o prisutnosti (ili odsutnosti) određenih ograničenja na način na koji se izvodi pokus.

Neke od njih se odnose na način na koji se rješava faktor buke, u kojima su faktori buke nepoznati i nekontrolirani, potpuno randomizirane izvedbe je najbolji način da se efekti jednoliko rasporede. Kada su faktori buke poznati i moguće ih je kontrolirati, blokiranje je metoda za eliminiranje njihovih efekata, randomizacijom provođenom unutar svakog bloka.

Međutim, postoje slučajevi kada to nije izvedivo, faktori interesa mogu teško varirati dok drugi faktori se mogu jednostavno. Redoslijed kojim se izvodi pokus je određen redom tih faktora koji se teško variraju. Za iste postavke, izvoditi se mogu sekvencijalno (varirajući samo faktore koji se lako mijenjaju), bez ponovnog postavljanja između izvođenja. U takvim pokusima svaka postavka faktora koji se teško mijenjaju naziva se parcela (pojam naslijeđen iz poljoprivrednih primjena). Ugniježđena vrsta pokusa koristi se kada su razine jednog ili više faktora slične, ali nisu identične za različite razine drugog faktora. Primjer bi mogla biti tvrtka koja kupuje tri serije sirovina od tri različita dobavljača i treba usporediti njihovu kvalitetu. Ako su serije od svakog dobavljača jedinstvene za tog određenog dobavljača, eksperiment bi trebao biti izveden kao ugniježđeni.

2.1.3. Cilj pokusa

Probir faktora (eng. Screening), procesi su često opisani velikom brojem faktora, čija se važnost ne može odrediti posebno u ranoj fazi izrade i razvoja procesa kada nam je znanstveno i inženjersko znanje o procesu ograničeno. Primjena DOE-a za utvrđivanje najutjecajnijih kontroliranih faktora procesa ključna je za konačno poboljšanje procesa. Bez odgovarajućeg pokusa probiranja potrošit će se značajna količina vremena na pogađanje koji su faktori važni.

Karakteriziranje (eng. Characterising), DOE se može koristiti za utvrđivanje kako kontrolirani faktori procesa, koji su već utvrđeni kao važni, trebaju prilagoditi tako da se prosječna vrijednost mjere učinkovitosti može dovesti na željenu razinu. Isto tako se može koristiti za određivanje gdje namjestiti najutjecajnije kontrolirane faktore kako bi se varijabilnost odziva oko ciljane razine minimizirala.

Optimiziranje (eng. Optimising), namještanje najutjecajnijih kontroliranih faktora procesa na razinu ili postavku tako da dobivamo najbolje dostižne uvijete rada. U slučaju ako nam je cilj što veći odziv moramo odrediti postavke najutjecajnijih kontroliranih faktora.

2.1.4. Pionir pristupa

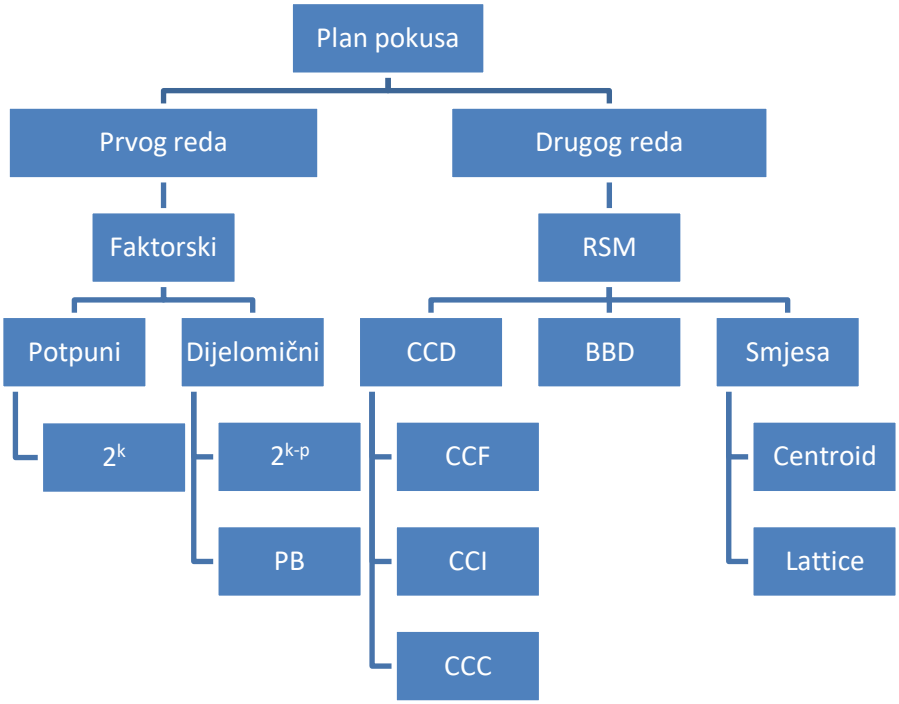
Pioniri "konvencionalnim" ili klasičnim" pristupa bili su Sir R. A. Fisher te kasnije George Box. Jedna od glavnih značajki ovog pristupa jest da je usmjerena na proučavanje prosječnog odziva i njegove varijacije oko ciljane vrijednosti zajedno s uzrocima te varijacije tj. kontrolnih faktora. Pri obavljanju ovih pokusa snažno se zagovara sekvencijski i adaptivni pristup. Počinjemo s pokusom probiranja faktora drugoga reda kako bi utvrdili ključne faktore te nakon toga slijedi pokus optimiziranja s faktorima na više od dva reda za proučavanje njihovih nelinearnih efekata i utvrđivanje njihovih najboljih postavki.

S druge strane, Taguchijev pristup usredotočuje se na proučavanje varijacija oko cilja prosječnog odziva i oko cilja pojedinih odziva i njihovog prosjeka. Naglašava važnost uključivanja uzroka obje vrste varijacije kontrolnih faktora i faktora buke u eksperimentu. Taguchi zagovara jedan eksperimentalni pristup gdje se koristi dizajn ukrštenog niza (eng. crossed array) koji sadrži unutarnji niz koji sadrži kontrolne faktore, a vanjski sadrži faktore buke. Taguchi uvodi novu statistiku performansi varijabilnosti koja se naziva odnos signal-šum (S/N) koja predstavlja omjer prosjeka (signal) i varijance (šum) i koja je izravno povezana i izvedena iz Taguchijeve funkcije gubitka.

Glavni cilj Shainin DOE je utvrđivanje najutjecajnijih parametara na performanse procesa. Shainin (1988) predložio je metodologiju od pet koraka za provedbu tog pristupa. Prva četiri koraka mogu se smatrati sustavnom potragom za ključne uzroke varijacije korištenjem statističkih tehnika kao intervala pouzdanosti i statističke kontrole procesa (eng. Statistical Process Control, SPC). Peti korak uključuje provođenje konvencionalne faktorijale za određivanje najboljih postavki ključnih faktora. Glavna prednost ovog pristupa je njegova jednostavnost.

2.2. Klasifikacija plana pokusa prema redu modela

U nastavku je detaljno opisana klasifikacija plana pokusa prema redu modela koji procjenjujemo (Slika 5).



Slika 5. Klasifikacija plana pokusa prema redu modela

2.3. Faktorski plan pokusa na dvije razine - 2^k

Faktorski plan pokusa (potpuni plan pokusa) s faktorima na dvije razine naširoko se koriste jer su jednostavni za projektiranje, učinkoviti u izvođenju, jednostavni za analizu i daju puno informacija. Faktorski plan pokusa sadrži sve moguće kombinacije faktora. Zbog toga je veći trošak na resurse za izvođenje svih kombinacija pokusa. Pokus na dvije razine se koristi kako bi se identificirali najvažniji faktori. Za ispitivanje k faktora na dvije razine potreban nam 2^k broj izvedba pokusa (kombinacija) [1].

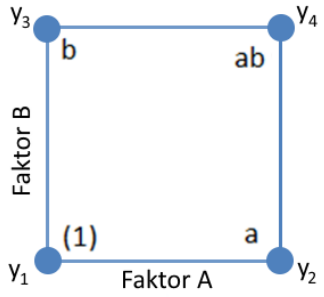
2.3.1. Faktorski plan pokusa - 2^2

Prvi faktorski plan pokusa 2^k serije pokusa je 2^2 faktorski plan pokusa. Sastoji se od dva faktora, označenih sa A i B, koje izvodimo na dvije razine. Razine faktora mogu se proizvoljno nazvati niskim i visokim. "a" se odnosi na učinak faktora A, "b" se odnosi na učinak faktora B, a "ab" se odnosi na AB interakciju. U 2^2 dizajnu, niska i visoka razina A i B označene su s "-1", odnosno "1" na osi A i B (Tablica 1).

Tablica 1. Faktorski plan pokusa 2^2

Oznake	Faktori	
	A	B
(1)	-1	-1
a	1	-1
b	-1	1
ab	1	1

Može se primijetiti da je zbroj termina koji proizlaze iz umnoška bilo koja dva stupca matrice pokusa jednak nuli. Kao rezultat, dizajn 2^2 je ortogonalni dizajn. Svi su 2^k dizajni ortogonalni. To svojstvo 2^k dizajna nudi veliku prednost u analizi zbog pojednostavljenja koja proizlaze iz ortogonalnosti. Faktorski plan pokusa 2^2 prikazan je grafički na (slici 6).



Slika 6. Grafički prikaz 2^2 faktorskog plana pokusa

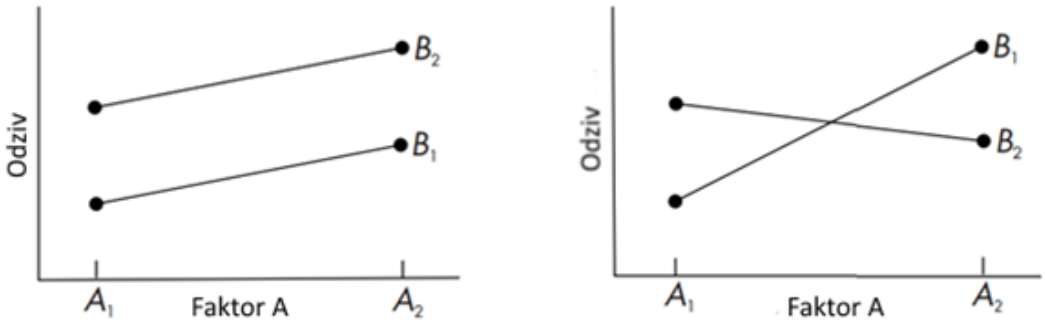
Učinak faktora definiramo kao promjena u odzivu nastala promjenom razine faktora. Zovemo ga glavnim učinkom zato što se odnosi na glavne faktore u pokusu. Glavni učinak faktora A jednak je razlici između prosječne vrijednosti odziva na nižoj i na višoj razini (4).

$$A = \frac{(y_2 + y_4)}{2} - \frac{(y_1 + y_3)}{2} \quad \textbf{(4)}$$

Glavni učinak faktora B prema tome je dan izrazom (5)

$$B = \frac{(y_3 + y_4)}{2} - \frac{(y_1 + y_2)}{2} \quad \textbf{(5)}$$

Ako razlika odziva između razina jednog faktora nije ista na razinama drugih faktora, to nam ukazuje da dolazi do međudjelovanja faktora. (Slika 7a) pokazuje odnos faktora bez međudjelovanja dok (Slika 7b) pokazuje međudjelovanja faktora A i B (linije nisu paralelne).



a) b)

Slika 7. a) Odziv faktora A bez međudjelovanja faktora B, b) sa međudjelovanjem faktora B

2.4. Djelomični faktorski plan pokusa - 2^{k-p}

Kako se broj faktora u 2^k faktorskom planu pokusa povećava, broj potrebnih izvedbi za potpuni plan brzo nadmašuje sredstva većine eksperimenata. Na primjer, za potpunu izvedbu 2^7 faktorskog plana pokusa potrebno je 128 izvedba pokusa. Ako pretpostavimo da određene interakcije višeg reda su zanemarive, informacije o glavnim efektima i interakcijama nižeg reda možemo dobiti provođenjem samo djela cijelog faktorskog plana pokusa.

2.4.1. Osnovni princip

U djelomičnom faktorskom planu na dvije razine 2_R^{k-p}, k je broj faktora, p označava veličinu frakcije 2^k faktorskog plana a R rezoluciju metode. Samo se (1⁄2)p totalnog broja 2^k kombinacija provodi. Pokus 2^{k-1} zahtijeva samo pola dok 2^{k-2} četvrtinu eksperimenta. Pretpostavimo da odaberemo četiri kombinacije tretmana a, b, c i abc kao svoju polovinu frakcije (Tablica 2).

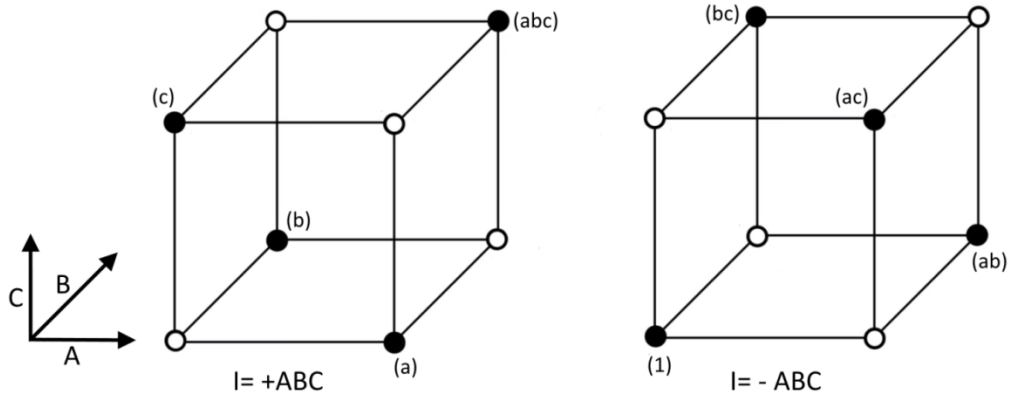
Tablica 2. Djelomični faktorski plan pokusa

Oznake	Faktori							
	I	A	B	C	AB	AC	BC	ABC
(1)	+	+	-	-	-	-	+	+
a	+	-	+	-	-	+	-	+
b	+	-	-	+	+	-	-	+
ab	+	+	+	+	+	+	+	+
c	+	+	+	-	+	-	-	-
ac	+	+	-	+	-	+	-	-
bc	+	-	+	+	-	-	+	-
abc	+	-	-	-	+	+	+	-

Pokus 2^{3-1} oblikovan je odabirom samo onih kombinacija koje imaju plus u ABC stupcu. ABC nazivamo generatorom frakcije. Nadalje, stupac identiteta I također je uvijek plus, pa vrijedi (6):

$$I = ABC \tag{6}$$

Općenito, definirajući odnos za djelomični faktorski plan pokusa uvijek će biti skup svih stupaca koji su jednaki stupcu identiteta I. Grafički prikaz predznaka generatora prikazan je na slici 8.



Slika 8. Djelomični faktorski plan pokusa [1]

Linearne kombinacije promatranja koje se koriste za procjenu glavnih efekata A (7), B(8) i C (9):

$$|A| = \frac{1}{2}(a - b - c + abc) \tag{7}$$

$$|B| = \frac{1}{2}(-a + b - c + abc) \tag{8}$$

$$|C| = \frac{1}{2}(-a + b + c + abc) \tag{9}$$

gdje se [A], [B] i [C] koriste za označavanje linearnih kombinacija povezanih s glavnim efektima. Linearne kombinacije promatranja koja se koriste za procjenu dvofaktorskih interakcija BC (10), AC (11) i AB(12):

$$|BC| = \frac{1}{2}(a - b - c + abc) \tag{10}$$

$$|AC| = \frac{1}{2}(-a + b - c + abc) \tag{11}$$

$$|AB| = \frac{1}{2}(-a + b + c + abc) \tag{12}$$

Iz toga slijedi da [A] = [BC], [B] = [AC] i [C] = [AB]. Prema tome se ne može razlikovati A i BC, B i AC i C i AB. Kada procjenjujemo A, B i C, stvarno procjenjujemo A + BC, B + AC i C + AB. Efekte sa ovim svojstvom nazivamo združenima (eng. aliased).

2.4.2. Rezolucija dizajna

Pojam koji opisuje stupanj do kojeg su procijenjeni glavni učinci združeni (ili confudirani) s procijenjenim interakcijama na 2 razine, interakcijama na 3 razine itd. Rezolucija se označuje rimskim brojevima. Općenito, razlučivost dizajna veća je za jedan od interakcije najmanjeg reda s kojom je neki glavni efekt združen. Ako su neki glavni efekti združeni s nekim interakcijama druge razine, rezolucija je III. Dizajni rezolucije III, IV i V posebno su važni [1].

- Dizajn rezolucije III. To su dizajni u kojima nijedan glavni efekt nije združen s bilo kojim drugim glavnim efektom, ali glavni efekti su združeni s dvofaktorskim interakcijama, a neke dvofaktorske interakcije mogu biti međusobno združene.
- Dizajn rezolucije IV. To su dizajni u kojima nijedan glavni efekt nije združen s bilo kojim drugim glavnim efektom ili bilo kojom dvofaktorskom interakcijom, ali dvofaktorske interakcije su međusobno združene.
- Dizajn rezolucije V. To su dizajni u kojima nijedan glavni efekt ili dvofaktorska interakcija nisu združeni s bilo kojim drugim glavnim efektom ili dvofaktorskom interakcijom, ali dvofaktorske interakcije združene su s interakcijama s tri faktora.

Općenito, rezolucija dvorazinskog frakcijskog pokusa jednaka je broju slova u najkraćoj riječi u definicijskoj relaciji [1].

2.5. Plackett-Burman dizajn - PB

To su djelomični faktorski planovi pokusa na dvije razine koji su R.L Plackett and J.P. Burman predstavili 1946. godine. Koriste se za studiranje do n - 1 varijabli u n izvedbi gdje je n višekratnik od 4. Djelomični faktorski planovi s rezolucijom III, podržavaju samo linearne modele, zahtijevaju vrlo mali broj eksperimentalnih izvedbi po faktoru, dizajni s 12, 20, 24 i 28 izvedbi su od posebnog interesa i koriste se u klasičnom izboru faktora . Zato što se dizajn ne može prikazati kao kocka, ponekad se pokus naziva ne geometrijskim pokusom.

2.6. Metode odzivnih površina - RSM

Metodologija odzivnih površina (engl. Response surface methodology, RSM), skup je matematičkih i statističkih tehnika koje se koriste za modeliranje i analizu problema u kojima na odziv interesa utječe nekoliko varijabli, a cilj je optimizirati taj odziv. Razine faktora x_1 i x_2 koje maksimiziraju odziv procesa je funkcija razine oba faktora koju možemo opisati (13):

$$y = f(x_1, x_2) + \varepsilon \quad \textbf{(13)}$$

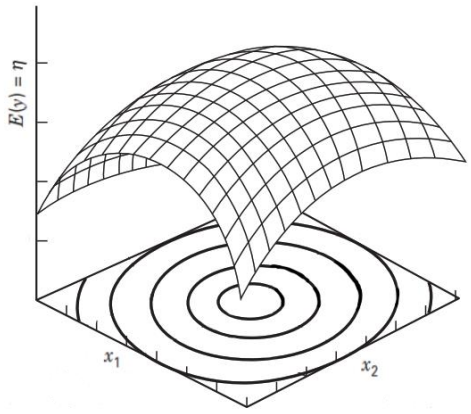
Gdje je:

ε šum ili grešku u odzivu y

Ako očekivani odziv označimo sa (14):

$$E(y) = f(x_1, x_2) = \eta \quad \textbf{(14)}$$

onda površina predstavljena s $\eta = f(x_1, x_2)$ se naziva odzivna površina. Obično odzivu površinu prikazujemo grafički, gdje je η ovisi o razinama x_1 i x_2. Kako bi bolje vizualizirali oblik odzivne površine crtamo konture. U konturnom dijagramu linije označavaju konstantne odzive (Slika 9). Svaka kontura odgovara određenoj visini površine odziva.



Slika 9. Prikaz kontura dijagrama odzivne površine [1]

U većini problema sa odzivnim površinama oblik odnosa između odziva i neovisnih varijabli je nepoznat. Zbog toga je prvi korak pronalaženje odgovarajuće aproksimacije pravog funkcionalnog odnos između odziva i skupa neovisnih varijabli. Obično se koristi polinom niskog reda u nekoj regiji neovisnih varijabli.

Ako je odziv dobro modeliran linearnom funkcijom neovisnih varijabli, tada aproksimirajuća funkcija model prvog reda glasi:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_3 x_3 + \varepsilon \quad \textbf{(15)}$$

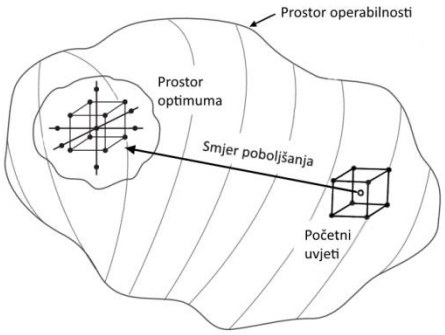
ako postoji zakrivljenost u sustavu, tada koristimo polinom višeg stupnja, kao što je model drugog reda

$$y = \beta_0 + \sum_{i=1}^{k} \beta_i x_i + \sum_{i=1}^{k} \beta_{ii} x_{ii}^2 + \sum_{i=1}^{k} \sum_{i \neq j=1}^{k} \beta_{ij} x_i x_j + \varepsilon \qquad \textbf{(16)}$$

Sve metode koriste jedan ili oba modela. Mala je vjerojatnost da će polinomni model biti stvarna aproksimacija pravog funkcionalnog odnosa za cijeli prostor neovisnih varijabli, ali za relativno mali prostor djeluju prilično dobro. Metoda najmanjeg kvadrata koristi se za procjenu parametara u aproksimirajućim polinomima. Analiza odzivne površine provodi se na prilagođenoj površini. Ako je prilagođena površina odgovara aproksimaciji prave funkcije odziva, tada će analiza prilagođene površine biti približno jednaka analizi stvarnog sustava. Parametri modela se najbolje aproksimiraju ako je dobar tip modela odabran.

2.6.1. Sekvencijalnost eksperimenta

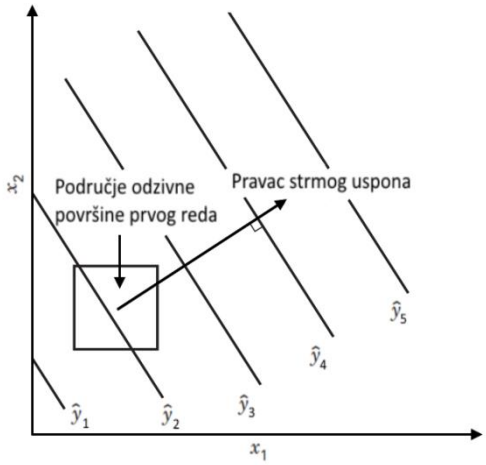
Jedna od najvažnijih karakteristika metode odzivnih površina je da se temelji na sekvencijalnom pristupu. Podaci dobiveni u početnim fazama eksperimentiranja koriste se u sljedećim fazama za poboljšanje dizajna. Često, kada smo na točki površine odziva koji je udaljen od optimalnog, kao što je prikazano na slici 10. stanjem početnih uvjeti, u sustavu je mala zakrivljenost i model prvog reda će biti prikladan. Cilj nam je brzo i učinkovito voditi pokus po smjeru poboljšanja što bliže prostoru optimuma. Nakon što je pronađen prostor optimuma, možemo upotrijebiti složeniji model, poput drugog reda, te možemo izvršiti analiza da bi se pronašao optimum.



Slika 10. Sekvencijalnost modela odzivnih površina [1]

2.6.2. Metoda strmog uspona

Početna procjena optimalnih radnih uvjeta sustava je obično daleko od stvarnog optimuma. U tom slučaju, cilj provoditelja pokusa je doći u neposrednu blizinu optimuma. Metoda strmog uspona (engl. method of steepest ascent) je postupak za sekvencijalno pomicanja u smjeru maksimalnog porasta odziva (pravac strmog uspona). Ako želimo minimizirati, onda ovu tehniku nazivamo metodom strmog silaska (eng. method of steepest descent).



Slika 11. Metoda strmog uspona [1]

2.7. Plan pokusa za podešavanje odzivne površine drugog reda

Da bi se procijenio termin drugog reda za određeni faktor, moraju biti najmanje tri razine tog faktora u eksperimentalnom dizajnu.

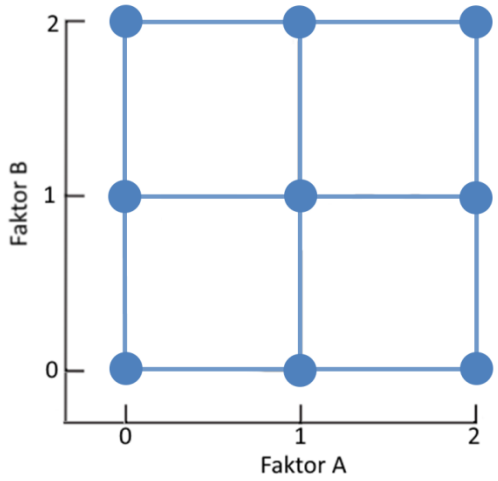
2.7.1. Faktorski plan pokusa na tri razine - 3^k

Ako je potrebno optimizirati postupak, možemo koristiti 3^k dizajn jer dopuštaju kvadratne modele. Na primjer, ako uzmemo u obzir faktorski plan pokusa 3^2 prikazanog na slici 12 gdje x_1 predstavljaju faktor A, a x_2 predstavljaju faktor B. Regresijski model koji odnosi odziv y na x_1 i x_2 koji je podržan ovim dizajnom

$$y = \beta_1 + \beta_1 x_1 + \beta_2 x_2 + \beta_{12} x_1 x_2 + \beta_{11} x_1^2 + \beta_{22} x_2^2 + \varepsilon \qquad \textbf{(17)}$$

Plan pokusa ima slične karakteristike kao i puni faktorski plan 2^2 ali uzimajući u model članove drugog reda. U slučaju dva faktora ima isti oblik kao plošno centrirani CCD. Za više faktora tada plan pokusu ima velik broj pokusa a time i neadekvatan zbog potrebe za što manjim brojem izvođenja pokusa. Dizajn na tri razine (3^k) nije najučinkovitiji način

modeliranja kvadratnog odnosa, preferira se centralno kompozitni plan koji zahtijeva manje izvedba za postizanje boljeg modela.



Slika 12. Kombinacije faktora u 3^2 dizajnu

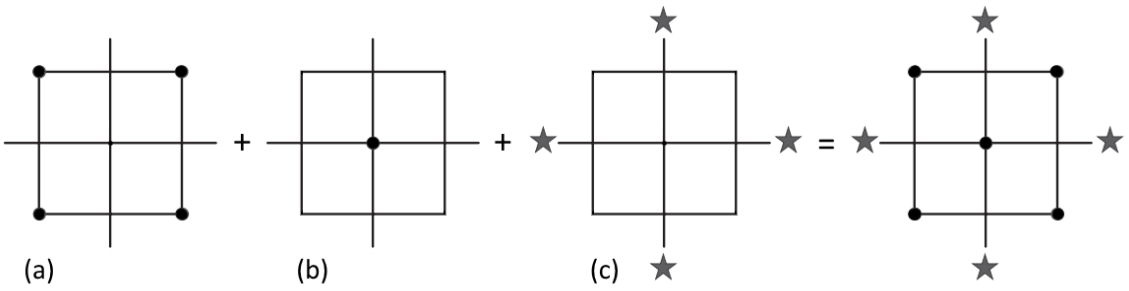
2.7.2. Centralno kompozitni plan - CCD

Centralno kompozitni plan (eng. Central composite design, CCD) je najpopularnija klasa planova pokusa za pokuse drugog reda.

Centralno kompozitni plan sastoji se od tri grupe točaka pokusa:

- Faktorski plan pokusa na dvije razine rezolucije V, sa točkama lociranim na vrhovima (Slika 13a). Broj točaka je k^2.
- Centralne točke koje pružaju podatak o nelinearnosti u odzivu. Najčešće se nekoliko puta repliciraju (Slika 13b). Broj točaka je n_c.
- Aksijalne točke (eng. axial points), ponekad se nazivaju i zvijezda točke, su aksijalno fiksirane točke koje su za α udaljene od centralne točke kako bi generirali parametre drugoga reda (Slika 13c). Broj točaka je 2k.

Sekvencijalna priroda plana pokusa vidljiva je u konstruiranju pokusa prema slici:



Slika 13. Konstrukcija centralno kompozitnog plana

Iz toga slijedi da je ukupan broj pokusa u centralno kompozitnom planu (18):

$$N = k^2 + 2k + n_c \quad \textbf{(18)}$$

Primjer matrice centralnog kompozitnog plana sa 3 faktora prikazan je u tablici 3.

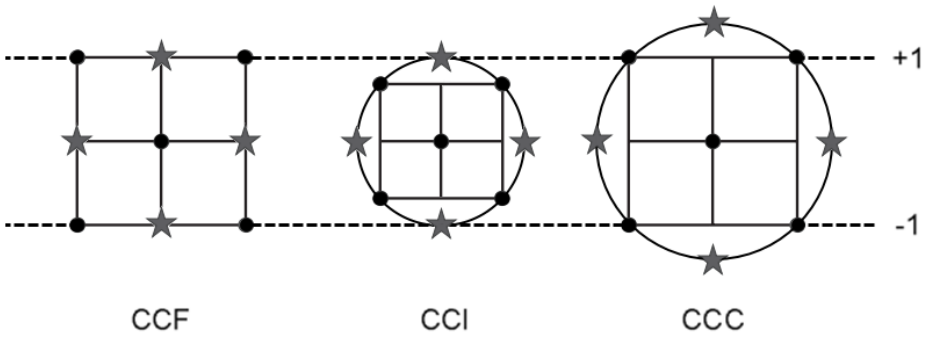
Tablica 3. Primjer izvedbe centralno kompozitnog plana sa 3 faktora

Faktorijske točke				Axijalne točke				Centralna točka			
1.	-1	-1	-1	9.	1,68	0	0	15.	0	0	0
2.	1	-1	--1	10.	-1,68	0	0				
3.	-1	1	-1	11.	0	1,68	0				
4.	1	1	-1	12.	0	-1,68	0				
5.	-1	-1	1	13.	0	0	1,68				
6.	-1	-1	-1	14.	0	0	-1,68				
7.	-1	1	1								
8.	1	1	1								

Alfa (α) je udaljenost svake aksijalne točke od središta dizajna. Računa se kao (19):

$$\alpha = (2^k)^{0,25} \quad \textbf{(19)}$$

Vrijednost alfa α = 1 je poželjna jer osigurava položaj aksijalne točke unutar područja faktorijala. Različiti modeli CCD plana pokusa obzirom na ograničenje prostora su prikazani na slici 14.



Slika 14. Različite strukture CCD: plošno centriran (CCF), upisan (CCI) i opisan(CCC)

2.7.3. Box -Behnken plan pokusa - BBD

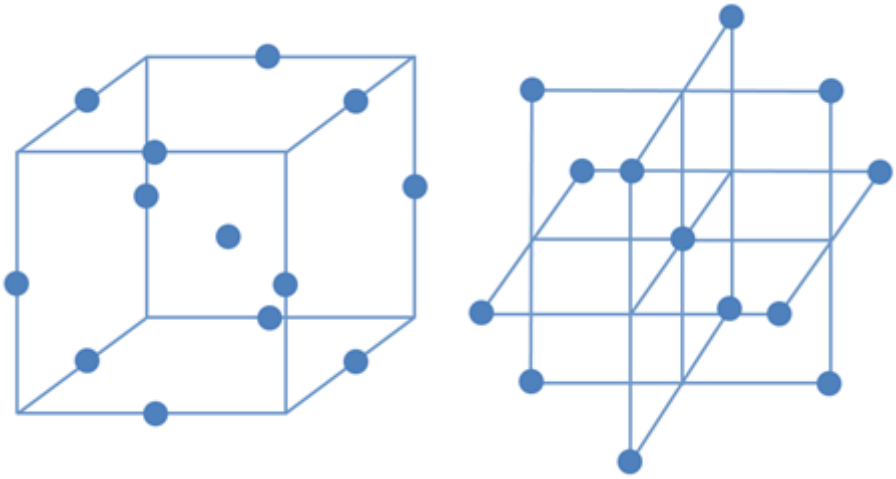
Box-Behnken plan pokusa (BBD) predstavlja obitelj plana pokusa na tri razine koji su rotabilni (ili vrlo blizu tome) te su vrlo učinkoviti za procjenu odzivnih površina drugog reda. BBD je tip metode odzivnih površina koji ne sadrži ugrađeni faktorski ili djelomični faktorski plan pokusa. Zbog toga nisu prikladni za sekvencijalne pokuse. Eksperimentalni prostor je

sferičan i treba se koristiti samo kada nas ne zanima predviđanje na kutovima kubne regije (krajnosti faktora).

Broj pokusa potrebnih za provođenje BBD definiran je izrazom (20):

$$N = 2k(k-1) + n_{cp} \tag{20}$$

Za tri faktora grafički prikaz može se prikazati u dva oblika: Kocka koja sadrži središnju točku i srednje točke rubova (Slika 15 a) i tri međusobno povezana 2^2 faktorska pokusa (Slika 15b), uključujući središnju točku.



a) b)

Slika 15. Box-Benken dizajn za 3 faktora i jednom centralnom točkom

2.8. Pokusi sa smjesama

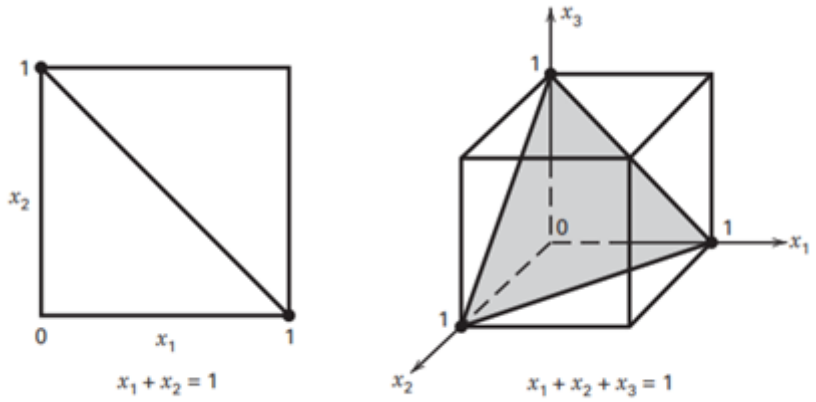
Pokusi sa smjesama su poseban tip pokusa metode odzivnih površina u kojemu su faktori sastojci ili komponente smjese, a odziv je funkcija proporcija svakog sastojaka. Jedinstveno obilježje pokusa sa smjesama je ograničenje smjese. Ako su x_1, x_2,..., x_q udjeli pojedinačnih sastojaka, q broj sastojaka smjese, onda vrijedi (21)(22) [3]:

$$x_i \geq 0; \;\; i = 1,2,3, \dots, q \tag{21}$$

$$\sum_{i=1}^{q} x_i = x_1 + x_2 + x_3 + \; \dots + x_q = 1 \tag{22}$$

Kao rezultat ovih ograničenja, udjeli komponenata međusobno su povezani i nemoguće ih je samostalno mijenjati. Ako se smjesa sastoji od samo jednog sastojka nazivamo ju čistom smjesom. Ona nam služi kao normativ za uspoređivanje sa smjesama s više sastojaka.

Za standardni pokus sa smjesom, eksperimentalno područje je (q - 1) dimenzionalni simpleks. Grafički prikaz ograničenja (1) i (2) za q = 2 i q = 3 sastojaka prikazan je na slici 16.



a) b)

Slika 16. Ograničeni faktorski prostor za smjese s a) 2 komponente i b) 3 komponente [1]

2.8.1. Kanonski polinomi za pokuse sa smjesama

Modeli za probleme smjese razlikuju se od standardnih modela za faktorske pokuse. Primjerice, modeli za pokuse sa smjesama uglavnom nemaju sjecište ili konstantu, jer bi takav pojam bio linearno ovisan o zbroju sastojaka smjese. Seheffe je preporučio sljedeće kanonske oblike za modele sa smjesama:

Linearni (23):

$$E(y) = \sum_{i=1}^{q} \beta_i x_i \qquad \textbf{(23)}$$

Kvadratni(24):

$$E(y) = \sum_{i=1}^{q} \beta_i x_i + \sum_{1 \le i \le j}^{q} \beta_{ij} x_i x_j \qquad \textbf{(24)}$$

Posebni kubni(25):

$$E(y) = \sum_{i=1}^{q} \beta_i x_i + \sum_{1 \le i \le j}^{q} \beta_{ij} x_i x_j + \sum_{1 \le i \le j \le k}^{q} \beta_{ijk} x_i x_j x_k \qquad \textbf{(25)}$$

Puni kubni(26):

$$E(y) = \sum_{i=1}^{q} \beta_i x_i + \sum_{1 \le i \le j}^{q} \beta_{ij} x_i x_j + \sum_{1 \le i \le j}^{q} \gamma_{ij} x_i x_j \cdot (x_i - x_j) + \sum_{1 \le i \le j \le k}^{q} \beta_{ijk} x_i x_j x_k \quad \textbf{(26)}$$

2.8.2. Model elementarne rešetke - Simplex lattice

Za podupiranje modela polinoma sa m stupnjeva i q komponenti preko cijelog elementarnog prostora, rešetka, određena sa {q,m} modelom elementarne rešetke sastoji se od točaka čije koordinate su definirane slijedećom kombinacijom udjela komponenata. Udjeli podrazumijevaju da će svaka komponenta zauzeti m + 1 jednako raspoređenih vrijednosti u intervalu [0,1], što znači (27) [3]:

$$x_i = 0, \frac{1}{m}, \frac{2}{m}, \cdots, 1 \text{ za } i = 1,2, \dots, q \quad \textbf{(27)}$$

Broj točaka u modelu elementarne rešetke može se izračunati na sljedeći način (28):

$$N = \frac{(q + m - 1)!}{m!\,(q - 1)!} \quad \textbf{(28)}$$

2.8.3. Elementarni model s težištem - Simplex centroid

Elementarnom modelu s težištem sa q komponentni broj točaka iznosi 2^q-1. Te točke odgovaraju q permutacija (1,0,0,0, …, 0) ili q čistih smjesa, $\binom{q}{2}$ permutacija (1 /2, 1 /2,0,0, …, 0) ili sve binarne mješavine i tako dalje sve do konačne točke težišta (1 /q, 1 /q, 1 /q, 1 /q, …, 1 /q) ili q-te mješavine.

Za zadani broj komponenata postoji samo jedan elementarni model s težištem, dok su mogući različiti modeli elementarne rešetke. Posebno je prikladan za primjenu posebnog kubnog kanonskog polinoma ili u model drugog reda [3].

2.8.4. Pokusi sa smjesama sa ograničenjima

Fizikalna, kemijska ili ekonomska razmatranja u pokusima sa smjesama često nameću ograničenja na razine sastojaka u smjesama. Zbog toga cijeli eksperimentalni prostor nije izvediv. Definiranje regije interesa ima važnu ulogu u oblikovanju i analizi pokusa sa

smjesama. Uvođenjem donjeg (l_i) i/ili gornjeg (u_i) ograničenja proporcije smjese reducira se prostor faktora na subregiju (29) [3]:

$$0 \leq l_i \leq x_i \leq u_i \leq 1 \quad \textbf{(29)}$$

Ako su u pokusu nametnuta donja ograničenja na sve ili pojedine komponente rezultirajuća subregija zadržava simpleks oblik (30)(31).

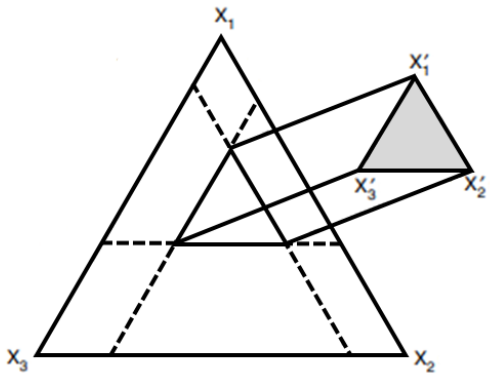
$$0 \leq l_i \leq x_i \leq 1 \quad \textbf{(30)}$$

$$\sum_{i=1}^{q} l_i < 1 \quad \textbf{(31)}$$

Ako su donja ograničenja jednaka za svaku komponentu, centroid subregije jednak je centroidu prostora faktora. Kako bi opisali odzivnu površinu nad subregijom sa polinomnom jednadžbom, model možemo opisati korištenjem izvornih komponenta smjese s ograničenjem ili pseudo komponentna transformacija donjih granica. Izračun modela je jednostavniji kada koristimo pseudo komponentnu transformaciju. Transformaciju x_i' L-pseudo komponente definiramo izrazom (32) :

$$x'_i = \frac{x_i - l_i}{1 - \sum_{i=1}^{q} l_i} \quad \textbf{(32)}$$

Rezultirajuća subregija za pokus (Slika 17) sa smjesama sa tri komponente (x_1, x_2, x_3) ograničena donjim granicama transformirana rezultira u potpuni simpleks sa L-pseudo komponentama x'_1, x'_2 i x'_3



Slika 17. Transformacija L-pseudo komponenta

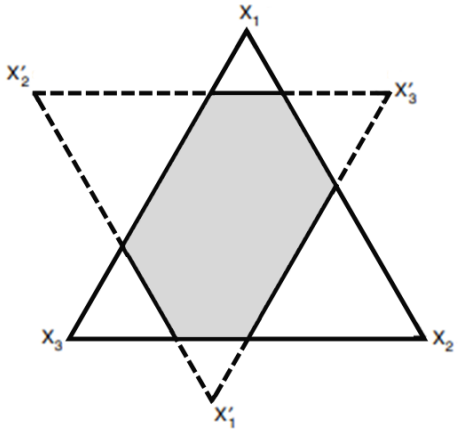
Gornja ograničenja na sve ili pojedine komponente u pokusu sa smjesama mogu se definirati izrazom (33):

$$0 \leq x_i \leq u_i \leq 1 \quad \textbf{(33)}$$

Kako bi transformirali ograničeni simplex u standardni simplex koristimo sljedeću jednadžbu za transformaciju pseudo komponenata (34):

$$x'_i = \frac{u_i - x_i}{\sum_{i=1}^{q} u_i - 1} \quad \textbf{(34)}$$

Ako se granice pseudo simpleksa protežu izvan granica originalnog simpleksa, eksperimentalna regija je nepravilni hiper-poliedar. Slika 18 prikazuje dobivenu eksperimentalnu regiju sa šest vrhova.



Slika 18. Transformacija U-pseudo komponenta

U praksi komponente smjese su vrlo često ograničene donjim i gornjim ograničenjima. Pokus as smjesama ograničen sa donjim i gornjim ograničenjima možemo definirati (35):

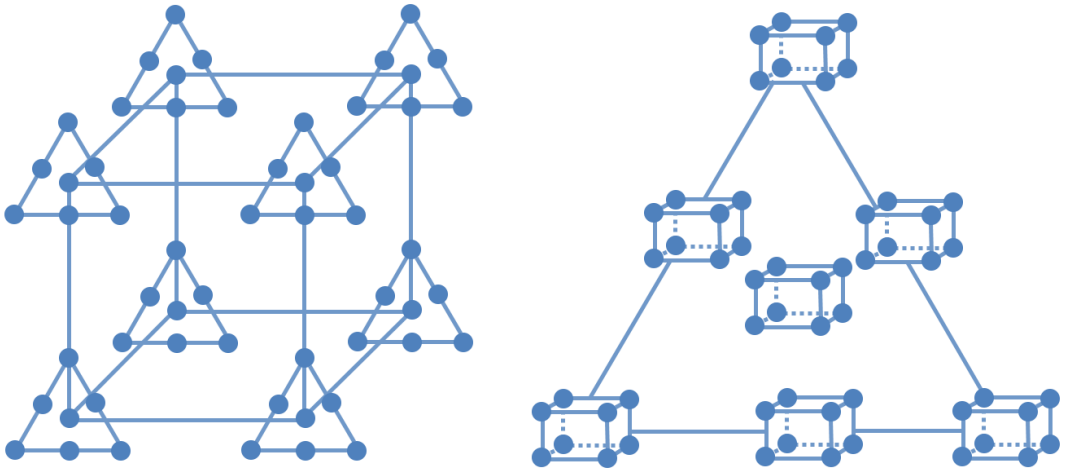
$$0 \leq l_i \leq x_i \leq u_i \leq 1 \quad \textbf{(35)}$$

Rezultirajuća subregija je homomorfna s ukupnim prostorom faktora u rasponu (u_i-l_i). Izvediva regija više nije simpleks, umjesto toga će biti nepravilni poliedar. Zato što je rezultirajuća eksperimenta regija više nije standardnog oblika, računalno generirani optimalni dizajni se koriste za rješavanje tih pokusa sa smjesama.

2.8.5. Pokusi sa smjesama s procesnim varijablama

Pokusi sa smjesama s prisutnošću procesnih varijabli obično se javljaju u proizvodnoj industriji. Provoditelj pokusa koji planira planirati pokuse sa smjesama u kojima postupak uključuje kombinaciju strojeva, metoda i drugih resursa, treba pronaći stanje faktora pokusa koji proizvod ili postupak čine robusnim na varijabilnost koja se prenosi u varijablu odziva. Procesne varijable su faktori u pokusu sa smjesama koji ne čine nijedan dio smjese, ali čija razina, kada se promijeni, utječe na svojstva sastojaka smjese. Eksperimentalno područje

pokusa sa smjesama s procesnom varijablom je kombinirano područje komponenata smjese i varijable procesa (Slika 19). Dimenzionalnost kombiniranog eksperimentalnog područja jednaka je zbroju dimenzionalnosti zasebnih eksperimentalnih područja.

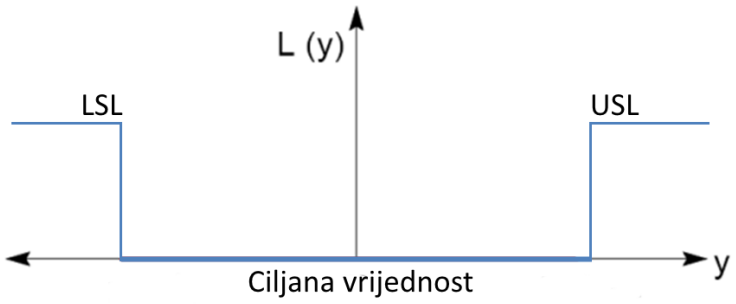


a) b)

Slika 19. a) Elementarni model s težištem na svakoj točki faktorskog plana pokusa 2^3, b) 2^3 faktorski plan pokusa na svakoj točki elementarnog modela s težištem [3]

2.9. Taguchijeva metoda

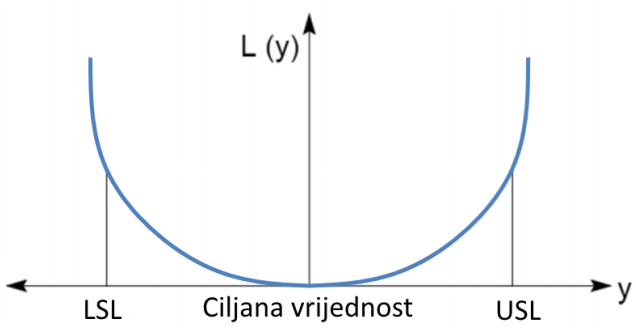
Prema tradicionalnom pristupu što se smatra dobrom kvalitetom je kad se proizvod nalazi unutar dopuštenih odstupanja (Slika 20), između donje (LSL) i gornje (USL) granice dopuštenih odstupanja. U tom pristupu granice dopuštenih odstupanja važnije su od ciljane vrijednosti.



Slika 20. Tradicionalni pristup definicije kvalitete

Taguchi definira kvalitetu kao devijaciju od ciljane vrijednosti. Prema njemu, kvaliteta proizvedenih proizvoda je stvoreni ukupni gubitak društvu od trenutka od kad se proizvod isporučuje. Pod gubitke Taguchi smatra gubitke nastale zbog varijabilnosti funkcije. Kada se

proizvod udalji od ciljane vrijednosti stvarat će se gubici iako se proizvod nalazi unutar dopuštenih odstupanja. Taguchijeva funkcija gubitaka prikazana je na slici 21 [4].



Slika 21. Taguchijev pristup definicije kvalitete

Prema Taguchiju gubitak nastao zbog varijacije performansi proporcionalan je kvadratu devijacije performansi karakteristike od svoje normalne vrijednosti. Matematički to možemo opisati s izrazom (36).

$$L(y) = K(X - m)^2 \tag{36}$$

Gdje je:

X	vrijednost značajke kvalitete
L	gubitak
m	ciljana vrijednost
K	konstanta ovisna o strukturi troškova gubitka

Glavni objektiv Taguchijeve metode je minimiziranje varijacije u odzivu proizvoda uz zadržavanje srednje vrijednosti odziva na ciljanoj vrijednosti, i stvaranje procesa robusnim na promjene u operativnim i okolišnim uvjetima. Kako bi postigli željenu kvalitetu proizvoda Taguchi preporučuje proces u tri faze:

- Određivanje sustava (eng. Systems design)- objektiv je naći vitalne faktore i njihove odgovarajuće razine koristeći se znanstvenim i inženjerskim znanjem.
- Određivanje parametara (eng. Parameter design) - objektiv je provođenje pokusa i određivanje optimalnih postavki faktora koji poboljšavaju radne karakteristike i smanjuju osjetljivost na izvore varijacije i šuma.
- Određivanje tolerancije odstupanja (eng. Tolerance design) - objektiv je određivanje užih tolerancija oko optimalnih postavki dobivenih tijekom određivanja parametara.

Dio planiranja Taguchijevog pokusa je odabir ortogonalnog niza. Taguchijeva metoda koristi ortogonalni niz za postizanje optimuma sa minimalnim brojem izvedbi. Ortogonalnost možemo opisati s izrazom (37).

$$\sum x_i \cdot x_j = 0 \qquad \textbf{(37)}$$

Izraz vrijedi za sve kombinacije razina gdje i, j predstavljaju visoke i niske razine. Ortogonalni faktori su okomiti jedni na druge. U ortogonalnom nizu svaki faktor ima jednaku težinu te je zbog toga pokus balansiran. Tablica 4 prikazuje potvrdu jednadžbe (37).

Tablica 4. Ortogonalni niz

Br	Faktor X1 - x_i	Faktor X2- x_j	$x_i \cdot x_j$
1	1	1	1
2	1	-1	-1
3	-1	1	-1
4	-1	-1	1
		$\sum x_i \cdot x_j$	0

Prednost ortogonalnosti je ta da se svaki faktor može procijeniti zasebno, tj. bez utjecaja ostalih faktora.

Nomenklatura ortagonalnog niza dana je jednadžbom (38).

$$L_a(b^c) \qquad \textbf{(38)}$$

Gdje je:

L latinski kvadrat (eng. Latin square)

a broj redova

b broj razina

c broj stupaca (faktora)

Primjer $L_8(2^7)$ ortogonalnog niza dan je u tablici 5.

Tablica 5. $L_8(2^7)$ ortogonalni niz

Broj ispitivanja	Stupci						
	1	2	3	4	5	6	7
1.	1	1	1	1	1	1	1
2.	1	1	1	2	2	2	2
3.	1	2	2	1	1	2	2
4.	1	2	2	2	2	1	1
5.	2	1	2	1	2	1	2
6.	2	1	2	2	1	2	1
7.	2	2	1	1	2	2	1
8.	2	2	1	2	1	1	2

Niska, odnosno visoka razina faktora označena je sa 1 i 2. Svaki stupac ima jednak broj jedinica i dvojki. Svaki par stupaca ima samo četiri kombinacije (1,1), (1,2), (2,1) i (2,2) što nam govori da su ortogonalni.

Omjer signal šum (eng. S/N ratio) je posebna vrsta sažetaka podataka koja kombinira dvije karakteristike u jednu, željene vrijednosti (signal) prema neželjenoj vrijednosti (šum), te se koristi u analiziranju podatka dobivenih u određivanju parametara. Omjer signal šum predstavlja rasipanje oko željene vrijednosti. Što je veća vrijednost manje je rasipanje. Taguchi definira tri situacije [4]:

Sredina je najbolje (eng. Nominal the best)

$$\frac{S}{N} = -10\log\left(\frac{s^2}{\bar{y}^2}\right) \tag{39}$$

Gdje je

$$y = \sum_{i=0}^{n} \frac{y_i}{n} \tag{40}$$

$$s^2 = \sum_{i=1}^{n} \frac{(y_i - \bar{y})}{(n-1)} \tag{41}$$

Manje je bolje (eng. Smaller the better)

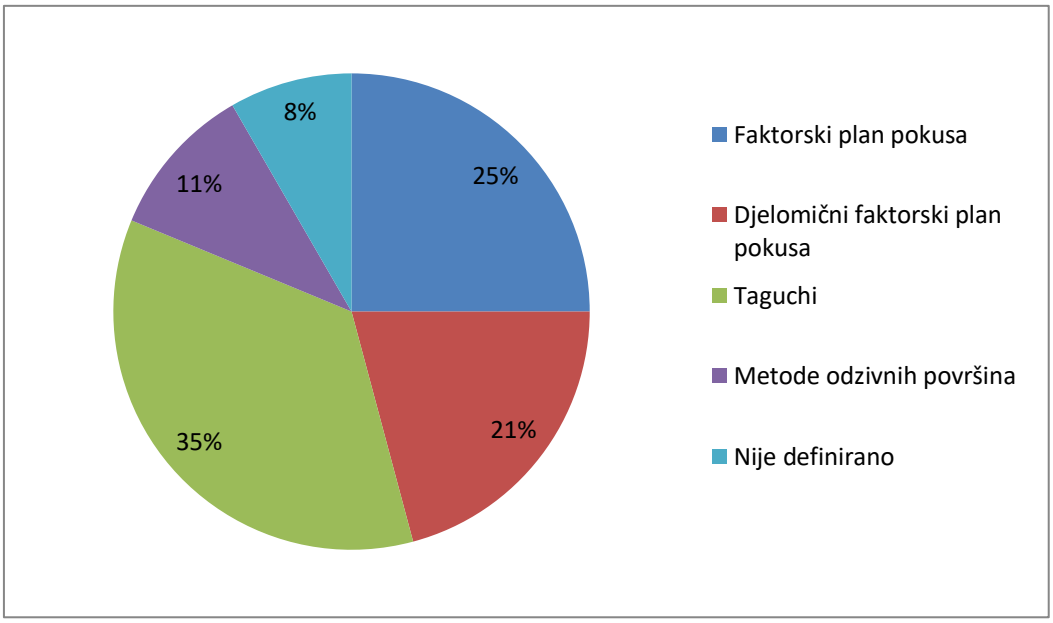
$$\frac{S}{N} = -10\log\frac{\sum_{i=1}^{n} {y_i}^2}{n} \tag{42}$$

Više je bolje (eng. Larger the better)

$$\frac{S}{N} = -10\log\frac{\sum_{i=1}^{n} \frac{1}{{y_i}^2}}{n} \tag{43}$$

3. NAJČEŠĆE KORIŠTENI MODELI PLANOVA POKUSA U PROCESU POBOLJŠANJA KVALITETE

Pomoću Scopus baze podataka pretraženi su znanstveni članci koji sadrže pojmove plan pokusa (eng. Design of experiments) i poboljšanje kvalitete (eng. Quality improvement) u zadnjih 10 godina. Slika 22 prikazuje graf raspodjele korištenja planova pokusa. Popis znanstvenih članaka nalazi se u tablici 6. Najčešće korišteni plan pokusa bio je Taguchijev ortogonalni plan pokusa.



Slika 22. Graf prikaz raspodjele plana pokusa

Tablica 6. Popis znanstvenih članaka

Ime autora	**Naslov, godina izdavanja**	**Metoda**
Beltrán N., Álvarez BJ.,	A design for additive manufacturing strategy for dimensional and geometrical quality improvement of polyjet-manufactured glossy cylindrical features, 2021	Faktorski plan pokusa
Psarommatis F.	A generic methodology and a digital twin for zero defect manufacturing (ZDM) performance mapping towards design for ZDM, 2021	Taguchi
Tannady H., Purwanto E.	Quality Control of Frame Production Using DMAIC Method in Plastic PP Corrugated Box Manufacture, 2021	Nije navedeno
Elsawah AM.	Multiple doubling: a simple effective construction technique for optimal two-level experimental designs, 2021	Faktorski plan pokusa
Chuenyindee T., Prasetyo T.	Roller Chains Quality Enhancement using Six Sigma and Failure Mode and Effects Analysis (FMEA), 2020	Faktorski plan pokusa
Wu J., Song	Robust Design for Multiple Quality Characteristics of	Taguchi

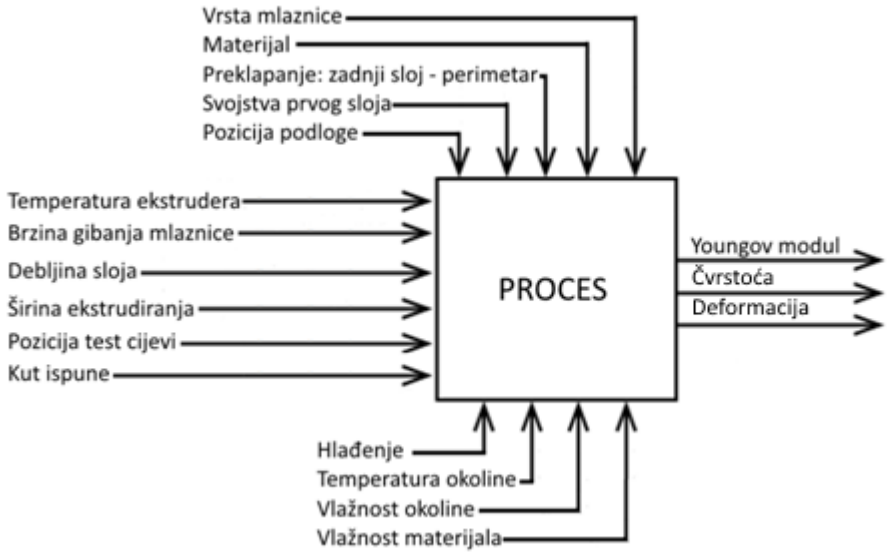
H.,Wan L.	Precision Product Using Taguchi-based Hybrid Method, 2020	
Neuhauser D., Provost SM., Provost LP.	It Is Time to Reconsider Factorial Designs: How Bradford Hill and R. A. Fisher Shaped the Standard of Clinical Evidence, 2020	Dijelomični plan pokusa
Sarghini F., De Vivo A.	Optimal shape design of supported structure for inner race track grinding machine, 2020	RSM
Wang Y., Gan. Y., Liu H.,	Surface Quality Improvement in Machining an Aluminum Honeycomb by Ice Fixation, 2020	Taguchi
Soundararajan K., Reddy KJ.	Quality improvement through the application of quality tools and simulation technique: A case study in a SME, 2020	Taguchi
Eguren JA., Esnaola A.	Modelling of an additive 3d-printing process based on design of experiments methodology, 2020	Dijelomični plan pokusa
Ziout A., Qudeiri JE.,	Application of Tagushi design in quality improvement for construction industry, 2020	Taguchi
Sirimongkol W.,Chutima P.	Defect reduction in forming process of fired clay floor tiles by six sigma approach, 2020	Faktorski plan pokusa
Carneiro F., Valdoleiros D.	Applying lean six sigma methodologies for quality improvement in a powder coatings industry, 2020	Faktorski plan pokusa
Feng Q., Liu L.,Zhou X.	Automated multi-objective optimization for thin-walled plastic products using Taguchi, ANOVA, and hybrid ANN-MOGA, 2020	Taguchi
Shiau YR., Chang HM.	Fuzzy assessment analysis and key improvements to a production system, 2019	Dijelomični plan pokusa
Homrossukon S.	Process and Product Quality Improvement of Pivot Assembly Process, 2019	Faktorski plan pokusa
Şimşek B., Pakdil F.	Building a Graphical User Interface for Concrete Production Processes: A Combined Application of Statistical Process Control and Design of Experiment, 2019	Taguchi
Golkarnarenji G.	A machine learning case study with limited data for prediction of carbon fiber mechanical properties, 2019	Taguchi
Hakimi S., Zahraee SM.	Application of Six Sigma DMAIC methodology in plain yogurt production process, 2018	Dijelomični plan pokusa
Muhammad K., Karningsih P.	Development of quality improvement matrix: An integrated tools for quality improvement, 2018	Nije navedeno
Almeida FA., Gomes GF.	A gage study applied in shear test to identify variation causes from a resistance spot welding measurement system, 2018	Dijelomični plan pokusa
Durakovic B.	Design of experiments application, concepts, examples: State of the art, 2017	Dijelomični plan pokusa
Mahato S., Dixit AR.,	Application of Lean Six Sigma for cost-optimised solution of a field quality problem: A case study, 2017	Faktorski plan pokusa
Chaturvedi S., Chakrabarti D.	Operational efficiency in manufacturing process using design of experiments, 2017	Dijelomični plan pokusa
Makary MS.	Design-of-Experiments Approach to Improving Inferior Vena Cava Filter Retrieval Rates, 2017	Nije navedeno
Kim H., Park S., Kim H.	The optimum production method for quality improvement of recycled aggregates using sulfuric acid and the abrasion method, 2016	Taguchi

Jamaluddin H., Ghani JA	Quality improvement using Taguchi method in shot blasting process, 2016	Taguchi
Liu SF., Cheng JH,	A case study on FMEA-based quality improvement of packaging designs in the TFT-LCD industry, 2015	Nije navedeno
Yame A., Al-Werfalli D.	Applications of lean methodologies and quality improvement in textile industry, 2019	Faktorski plan pokusa
Becker W., Eckl W.	Near infrared spectroscopy as a tool for in-line control of process and material properties of PLA biopolymer, 2015	Dijelomični plan pokusa
Nekkanti V., Marwah A.	Media milling process optimization for manufacture of drug nanoparticles using design of experiments (DOE), 2013	RSM
Sant'Anna AMO.	Framework of decision in data modeling for quality improvement, 2015	Dijelomični plan pokusa
He Z., Zhang X., Xie G., Zhang M.	Earphone terminal quality improvement through sequential experimental design, 2015	RSM
Saikaew C., Poolpraserd C.	Effect of rice husk on the sand mold properties and the quality of cast iron, 2016	Faktorski plan pokusa
Solehati N.	Optimization of plastic injection moulding process using data mining: A case study, 2014	Dijelomični plan pokusa
Aized T., Amjad M.	Quality improvement of deep-hole drilling process of AISI D2, 2013	RSM
Yan BJ., Guo ZT., Qu HB., Zhao T.	Feedforward control strategy and its application in quality improvement of ethanol precipitation process of Danhong injection, 2013	RSM
Thirumalai R. Senthilkumaar JS.	Multi-criteria decision making in the selection of machining parameters for Inconel 718, 2013	Taguchi
Pouliou MJ., Besseris G.	Robust screening of cake product characteristics by the Taguchi method, 2013	Taguchi
Liu X., Bai Z., Shuang Y.	Robust process design towards through-silicon via quality improvement based on Grey-Taguchi method, 2012	Taguchi
Besseris G.	Eco-design in total environmental quality management: Design for environment in milk-products industry, 2012	Taguchi
Lin WT., Wang ST., Li MH.	An analysis of an optical coating process capability prediction model in a Six Sigma procedure by integrating APIBPN and K-means, 2012	Taguchi
Savsar M., Al-Ajmi M.	A quality control application in healthcare management using experimental design criteria, 2012	Faktorski plan pokusa
Jamaluddin ZZ., Razali A.	Wafer dice process improvement using Six Sigma approach, 2011	Faktorski plan pokusa
Gkionis NP., Souliotis AS	Six Sigma's doe application on the mechanical effects of apple quality in industrial-level storage operations, 2011	Taguchi
Besseris GJ.	Applying the DOE toolkit on a lean-and-green Six Sigma maritime-operation improvement project, 2011	Taguchi
Dasgupta T., Adiga N.	Another look at Dorian Shainin's variable search technique, 2011	Faktorski plan pokusa

4. ANALIZA PRIMJERA DOBRE PRAKSE

4.1. Primjer djelomičnog plana pokusa: Modeliranje aditivnog 3D printanja baziranog na metodologiji planiranja pokusa [5]

Ovaj članak predstavlja rezultate studije provedene na novom 3D printeru. Glavni objektiv bio je određivanje kako pojedini faktori utječu na tehnologiju modeliranja topljenog taloženja (FDM, eng. fusion deposition modelling) u svrhu proizvodnje u maloj seriji, pred produkcijskoj proizvodnji i izradi prototipa. Kvaliteta i čvrstoća dijelova napravljenih FDM metodom ovisi o parametrima procesa. Za testiranje napravljeni su uzorci. Uzorci su napravljeni prema EN ISO 527-2 standardu. Kako bi testirali mehanička svojstva provedeno je vlačno ispitivanje napravljenih primjeraka. Slika 23 prikazuje najvažnije faktore koji utječu na model procesa i njihovu klasifikaciju.



Slika 23. Model procesa 3D printanja

U pokusu je analizirano šest faktora na dvije razine (Tablica 7).

Tablica 7. Razine faktora procesa 3D printanja

Faktor	Naziv	Jedinica	Niža razina	Viša razina
A	Temperatura	°C	180	200
B	Brzina mlaznice	mm/s	40	80
C	Debljina sloja	mm	0,1	0,3
D	Širina ekstrudiranja	mm	0,55	0,75
E	Pozicija test cijevi		Horizontalno	Vertikalno
F	Kut ispune	°	0	90

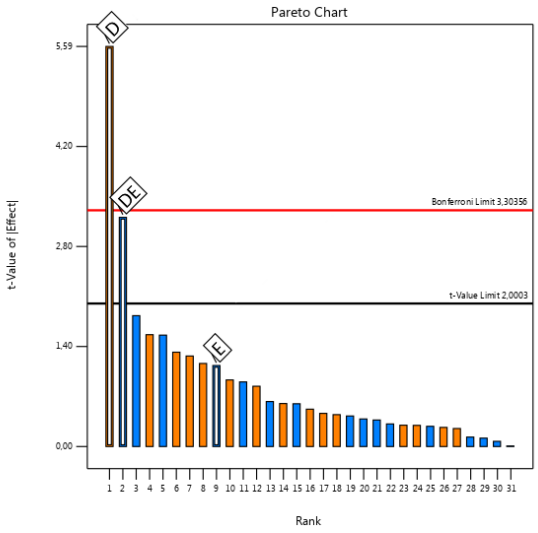
Odabran je djelomični plan pokusa 2^{6-1} rezolucije IV sa dvije replikacije za ukupno 64 pokusa. Za analiziranje odabrano je tri odziva: Youngov modul, čvrstoća i deformacija od kojih su Youngov modul i čvrstoća detaljno opisani u nastavku. Pokus je generiran u programu Design Expert 13 te je rezultantna matrica prikazan u tablici 8.

Tablica 8. Rezultantna matrica sa odzivima

Std	Run	Factor 1 A:Temperatura °C	Factor 2 B:Brzina mlaz... mm/sec	Factor 3 C:DEbljina sl... mm	Factor 4 D:Širina ekstr... mm	Factor 5 E:Pozicija tes...	Factor 6 F:Kut ispune °	Response 1 Youngov mo... GPa	Response 2 Čvrstoća MPa
40	1	200	80	0,1	0,55	Vertikalan	90	3,2	23,84
57	2	180	40	0,3	0,75	Vertikalan	90	2,59	28,99
53	3	180	80	0,1	0,75	Vertikalan	90	2,23	27,14
10	4	180	40	0,3	0,55	Horizontalan	90	3,17	42,7
6	5	180	80	0,1	0,55	Horizontalan	90	3,34	34,1
54	6	180	80	0,1	0,75	Vertikalan	90	1,39	6,6
13	7	180	80	0,3	0,55	Horizontalan	0	3,31	42,74
62	8	180	80	0,3	0,75	Vertikalan	0	2,57	34,97
25	9	180	40	0,3	0,75	Horizontalan	0	3,14	45,46
51	10	200	40	0,1	0,75	Vertikalan	90	3,53	60,76
9	11	180	40	0,3	0,55	Horizontalan	90	3,28	42,33
23	12	200	80	0,1	0,75	Horizontalan	90	2,38	34,89
11	13	200	40	0,3	0,55	Horizontalan	0	2,9	45,98
44	14	200	40	0,3	0,55	Vertikalan	90	3,14	45,55
1	15	180	40	0,1	0,55	Horizontalan	0	2,7	24,1
34	16	180	40	0,1	0,55	Vertikalan	90	3	18,77
29	17	180	80	0,3	0,75	Horizontalan	90	3,06	43,49
42	18	180	40	0,3	0,55	Vertikalan	0	3,12	33,42
32	19	200	80	0,3	0,75	Horizontalan	0	3,02	42,54
15	20	200	80	0,3	0,55	Horizontalan	90	3,4	55,63
22	21	180	80	0,1	0,75	Horizontalan	0	2,95	38,03
35	22	200	40	0,1	0,55	Vertikalan	0	3,24	18,17
33	23	180	40	0,1	0,55	Vertikalan	90	2,64	18,69
31	24	200	80	0,3	0,75	Horizontalan	0	3,38	42,96
26	25	180	40	0,3	0,75	Horizontalan	0	3,65	55,94
30	26	180	80	0,3	0,75	Horizontalan	90	3,27	53,64
45	27	180	80	0,3	0,55	Vertikalan	90	3,56	48,15
19	28	200	40	0,1	0,75	Horizontalan	0	2,49	31,36
3	29	200	40	0,1	0,55	Horizontalan	90	2,53	27,42
52	30	200	40	0,1	0,75	Vertikalan	90	1,86	12,04
14	31	180	80	0,3	0,55	Horizontalan	0	3,08	42,57
7	32	200	80	0,1	0,55	Horizontalan	0	2,47	25,06
38	33	180	80	0,1	0,55	Vertikalan	0	3,04	21,8
8	34	200	80	0,1	0,55	Horizontalan	0	2,82	32,25
5	35	180	80	0,1	0,55	Horizontalan	90	3,34	37,85
64	36	200	80	0,3	0,75	Vertikalan	90	2,7	36,81
2	37	180	40	0,1	0,55	Horizontalan	0	3,13	30,71
48	38	200	80	0,3	0,55	Vertikalan	0	3,44	55,49
49	39	180	40	0,1	0,75	Vertikalan	0	2,12	20,73
24	40	200	80	0,1	0,75	Horizontalan	90	2,84	35,53
55	41	200	80	0,1	0,75	Vertikalan	0	1,92	18,9
17	42	180	40	0,1	0,75	Horizontalan	90	2,29	32,06
21	43	180	80	0,1	0,75	Horizontalan	0	2,88	37,01
43	44	200	40	0,3	0,55	Vertikalan	90	3,14	38
63	45	200	80	0,3	0,75	Vertikalan	90	2,92	42,06
60	46	200	40	0,3	0,75	Vertikalan	0	1,68	14,05
58	47	180	40	0,3	0,75	Vertikalan	90	2,4	20,93
50	48	180	40	0,1	0,75	Vertikalan	0	3,83	20,31
18	49	180	40	0,1	0,75	Horizontalan	90	3,39	39,56
61	50	180	80	0,3	0,75	Vertikalan	0	2,54	26,24
46	51	180	80	0,3	0,55	Vertikalan	90	3,62	55,75
56	52	200	80	0,1	0,75	Vertikalan	0	2,84	27,87
39	53	200	80	0,1	0,55	Vertikalan	90	3,27	20,77
20	54	200	40	0,1	0,75	Horizontalan	0	3,23	43,15
37	55	180	80	0,1	0,55	Vertikalan	0	2,43	17,58
59	56	200	40	0,3	0,75	Vertikalan	0	1,86	16,94
47	57	200	80	0,3	0,55	Vertikalan	0	3,64	56,47
36	58	200	40	0,1	0,55	Vertikalan	0	2,94	20,65
16	59	200	80	0,3	0,55	Horizontalan	90	3,6	48,41
4	60	200	40	0,1	0,55	Horizontalan	90	3,07	30,64
12	61	200	40	0,3	0,55	Horizontalan	0	3,07	53,49
28	62	200	40	0,3	0,75	Horizontalan	90	2,89	37,14
27	63	200	40	0,3	0,75	Horizontalan	90	2,88	40,19
41	64	180	40	0,3	0,55	Vertikalan	0	3,52	50,57

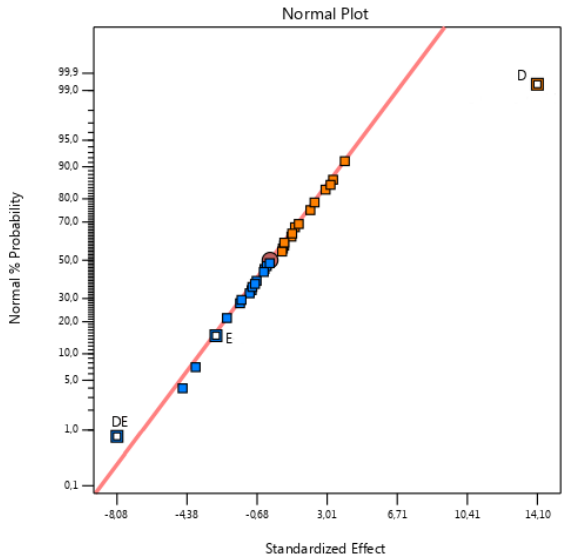
4.1.1. Analiza utjecaja na čvrstoću

Pareto dijagrami određuju veličinu i važnost efekata. U dijagramu stupci koji prelaze referentnu crtu statistički su značajni. Ta nam je informacija važna jer nam pomaže u odabiru faktora koji imaju značajan efekt. Iz Pareto dijagrama (Slika 24) vidljivo je da su utjecajan faktor D širina ekstrudiranja i interakcija DE na opterećenje pucanja.



Slika 24. Pareto dijagram za opterećenje pucanja

Iz normaliziranog papira možemo odrediti magnitudu i smjer efekata u jednom dijagramu. Normalizirani papir prikazuje standardizirane efekte u odnosu na liniju odgovarajuće raspodjele za slučaj kada su svi efekti jednaki 0. Iz dijagrama (Slika 25) je vidljivo da su utjecajni faktori D i interakcija DE.



Slika 25. Normalizirani papir za opterećenje pucanja

Značajnost modela i članova odzivnog polinoma određivana je analizom varijance prikazanom u tablici 9.

Tablica 9. Rezultati analize varijance

Izvor varijabilnosti	Suma kvadrata odstupanja SS	Stupnjevi slobode df	Srednji kvadrat odstupanja S^2	Varijabla F	Rizik odbacivanja hipoteze p	Značajnost
Model	4355,84	3	1451,95	14,28	<0,0001	Značajan
D	3181,81	1	3181,81	31,29	<0,0001	
E	130,42	1	130,42	1,28	0,2619	
DE	1043,61	1	1043,61	10,26	0,0022	
Ostatak	6101,15	60	101,69			
Odstupanje od modela	1839,04	28	65,68	0,4931	0,9695	Neznačajan
Čista pogreška	4262,11	32	133,19			
Ukupno	10456,99	63				

F vrijednost modela od 14,28 ukazuje na značajnost modela jer vjerojatnost da se pojavi vrijednost uslijed šuma iznosi manje od 0,01%. Svi faktori sa P vrijednosti manjom od 0,05 čine matematički model jer ih smatramo značajnim dok članove iznad ne smatramo. Vrijednost E nije odbačena iako je vrijednosni rizik odbacivanja hipoteze veći od 0,05 (0,2619) jer zbog hijerarhije mora ostati kako ne bi odbacili član DE. Veličina odstupanja (eng. Lack of fit) nam govori je li regresijski model loš model podataka. F vrijednost veličine odstupanja od modela od 0,4931 znači da ova veličina nije značajna u odnosu na čistu pogrešku. Postoji vjerojatnost od 97% da F vrijednost veličine odstupanja od modela nastaje od šuma. S obzirom da odstupanje od modela nije značajno model se može prihvatiti. Čista pogreška (eng. Pure error) je pogreška ponavljanja pojedinih stanja pokusa u svrhu procjene varijance odziva kao i broja stupnjeva slobode za statističko testiranje izrađenog modela [6].

U tablici 10 prikazani su osnovni statistički parametri modela.

Tablica 10. Statistički parametri modela

Standardna devijacija	10,08
Aritmetička sredina	34,81
Koeficijent varijacije %	28,97
Koeficijent determinacije - R^2	0,4165
Prilagođeni koeficijent determinacije - R^2_{adj}	0,3874
Predviđeni koeficijent determinacije - R^2_{pred}	0,3362
Adekvatna preciznost	8,7974

Koeficijent varijacije (C.V %) je omjer standardne devijacije i srednje vrijednosti. Što je veći koeficijent varijacije to je veća razina rasipanja oko aritmetičke vrijednosti Koeficijent determinacije (eng. R squared) je procjena ukupne varijacije podataka koja je objašnjena pomoću modela te je mjera odstupanja od aritmetičke sredine koje je objašnjena modelom. Što je koeficijent determinacije bliži 1 to model bolje slijedi podatke. Redukcijom modela, odnosno izbacivanjem većeg broja neznačajnih članova iz modela može doći do njegovog poboljšanja koje je određeno vrijednostima prilagođenog i predviđenog koeficijenta determinacije. Prilagođeni koeficijent determinacije (end. Adjusred R-Squared) definira iznos varijacije oko srednje vrijednosti objašnjene modelom, te uzima u obzir broj članova u matematičkom modelu u odnosu na broj stanja u planu pokusa. Predviđeni koeficijent determinacije (eng. Predicted R-Squared) je mjera iznosa varijacija u novim podacima objašnjenim pomoću modela. Razlika između te dvije vrijednosti mora biti manja od 0,2 inače postoji sumnja u vjerodostojnost podataka ili izrađenog matematičkog modela [6].

Adekvatna preciznost (eng. Adequate precision) mjeri odnos veličina signala u odnosu na šum, poželjna je vrijednost veća od 4. S obzirom da je u ovom slučaju omjer jednak 8,7974 imamo primjeren signal te se ovaj model može koristiti ta analizu u eksperimentalnom prostoru [6].

Predviđanje koeficijenta predstavlja očekivanu promjenu odziva po jedinici promjene u vrijednosti faktora kada su svi preostali faktori držani konstantnima. U tablici 11 prikazani su koeficijenti u kodiranim vrijednostima faktora.

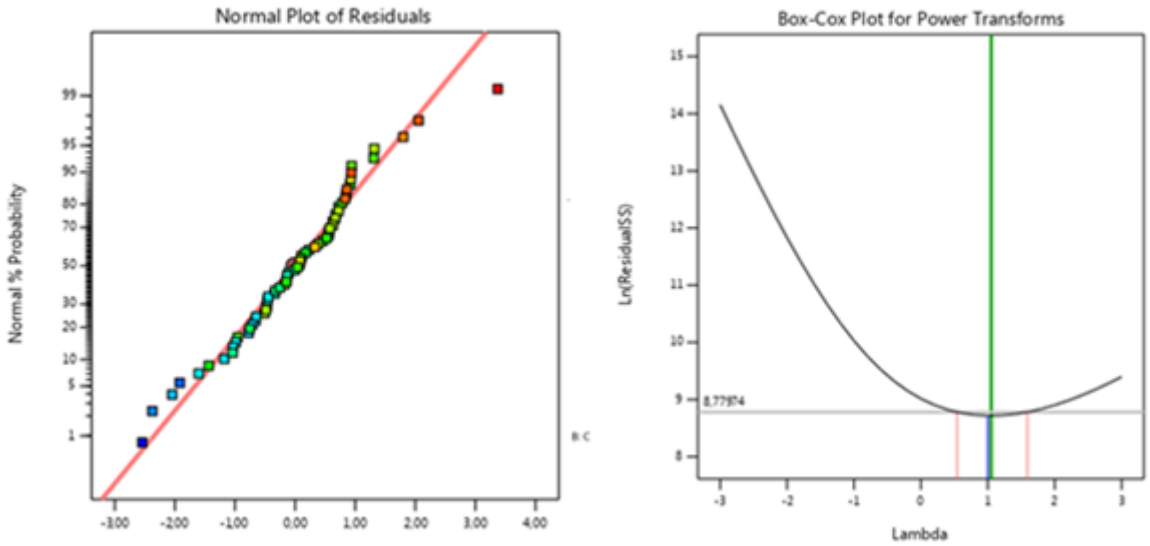
Tablica 11. Koeficijenti u kodiranim vrijednostima faktora

Faktor	Predviđanje koeficijenta	Stupnjevi slobode	Standardna pogreška	95% CI Niži	95% CI Viši
Interecept	34,81	1	1,26	32,29	37,33
D	7,05	1	1,26	4,53	9,57
E	-1,43	1	1,26	-3,95	1,09
DE	-4,04	1	1,26	-6,56	-1,52

Pod dijagnostikom testiramo valjanost rezultata pomoću dijagrama. Normalnost izmjerenih vrijednosti za pojedina stanja pokusa ispituje se normaliziranim papirom vjerojatnosti ostataka (eng. Normal plot of residuals) prikazanog na slici 26a. Normalizirani papir vjerojatnosti ostataka označava da li ostaci prate normalnu distribuciju u kojem slučaju će točke pratiti ravnu liniju. U slučaju da točke prate liniju "S" oblika to nam ukazuje da je

potrebna transformacija odziva da dobijemo bolju analizu. U ovom slučaju točke prate liniju pa ostaci prate normalnu distribuciju.

Box-Cox dijagram pokazuje da li je model dovoljan ili je potrebna transformacija. Nije potrebna transformacija zato što je lambda (lambda =1) unutar 95% raspona relativne pouzdanosti. Slika 26 b prikazuje Box-Cox dijagram.

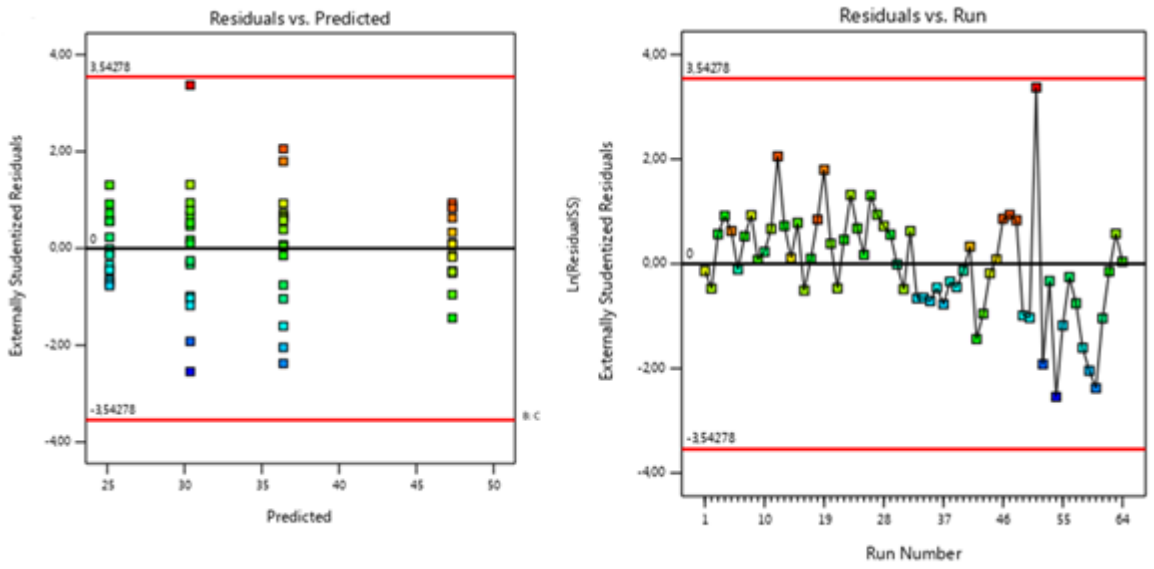


a) b)

Slika 26. a) Normalizirani papir vjerojatnosti ostataka, b) Box Cox dijagram

Slučajno rasipanje ostataka u odnosu na modelom izračunate (predviđene)vrijednosti za rezultate (eng. residuals vs predicted) prikazano je na slici 27a, a testira se pretpostavka konstantne varijance. Dijagram bi trebao biti slučajno raspršen (konstantan raspon ostataka u cijelom dijagramu). Proširivanje varijance u obliku "megafona" ukazuje na potrebu za transformacijom.

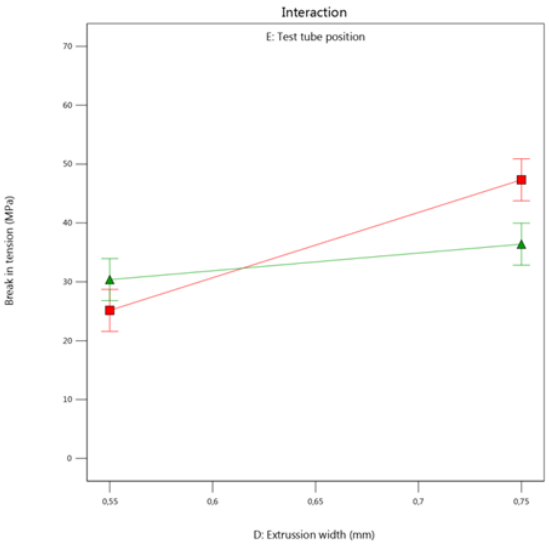
Slučajno rasipanje ostataka u odnosu na redoslijed izvođenja pokusa (eng. residuals vs run) prikazano je na slici 27b. Omogućava nam da provjerimo na postojanje skrivenih varijabli koje su možda utjecale na odziv tijekom pokusa. Dijagram bi trebao biti slučajno raspršen. U dijagramu tražimo ekstremne vrijednosti koje izlaze izvan linija. Niti jedan podatak ne prelazi granicu od ± 3,54278 pa su svi uključeni u opis modela.



a) b)

Slika 27. a) Slučajno rasipanje ostataka u odnosu na predviđene vrijednosti za rezultate, b) slučajno rasipanje ostataka u odnosu na redoslijed izvođenja pokusa

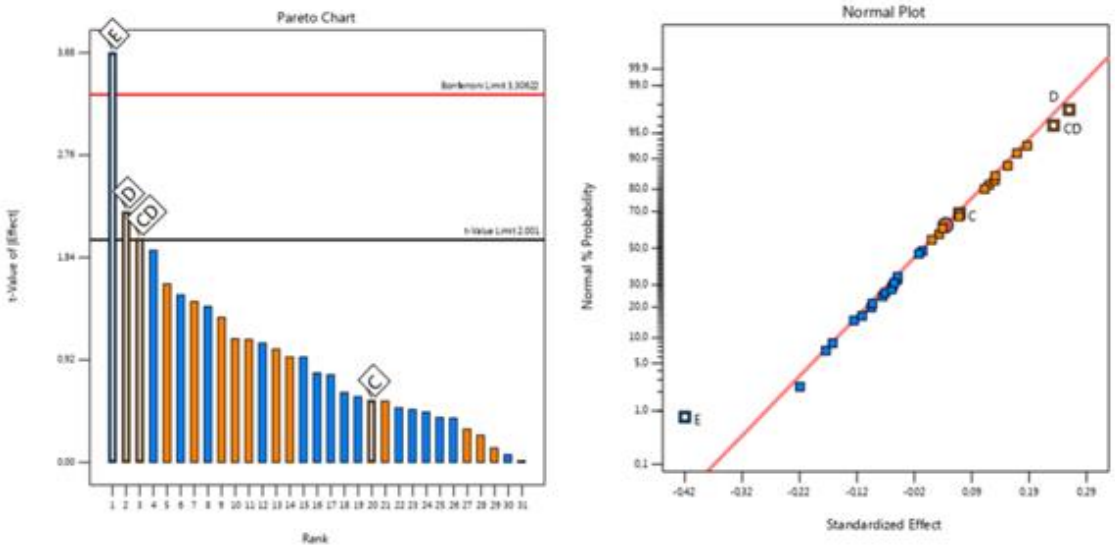
Slika 28 prikazuje grafički prikaz međudjelovanja faktora širine ekstrudiranja i pozicije test cijevi na opterećenje pucanja. Širina ekstrudiranja je na horizontalnoj osi. Crvena linija predstavlja horizontalnu poziciju test cijevi dok zelena predstavlja vertikalnu. Vidimo da za Horizontalnu poziciju opterećenje pucanja se povećava sa povećanjem širine ekstrudiranja isto kao i za vertikalnu poziciju no sa manjim usponom.



Slika 28. Grafički prikaz međudjelovanja faktora D i E na opterećenje pucanja

4.1.2. Analiza utjecaja na Youngov modul

Iz pareto dijagrama (Slika 29a) i iz normaliziranog papira vjerojatnosti (Slika 29b) vidljivo je da su utjecajni faktori E pozicija test tube i D širina ekstrudiranja te interakcija CD. U model ulazi i faktor C debljina sloja zbog hijerarhije.



a) b)

Slika 29. a) Pareto dijagram, b) normalizirani papir za Youngov modul

Značajnost modela i članova polinoma određena je analizom varijance prikazanom u tablici 12.

Tablica 12. Rezultati analize varijance

Izvor varijabilnosti	Suma kvadrata odstupanja SS	Stupnjevi slobode df	Srednji kvadrat odstupanja S^2	Varijabla F	Rizik odbacivanja hipoteze p	Značajnost
Model	4,78	4	1,19	5,74	0,0006	Značajan
C	0,0644	1	0,0644	0,3099	0,5799	
D	1,05	1	1,05	5,07	0,0281	
E	2,82	1	2,82	13,56	0,0005	
CD	0,8395	1	0,8395	4,04	0,0490	
Ostatak	12,26	59	0,2078			
Odstupanje od modela	5,01	27	0,1856	0,8196	0,6990	Neznačajan
Čista pogreška	7,25	32	0,2265			
Ukupno	17,04	63				

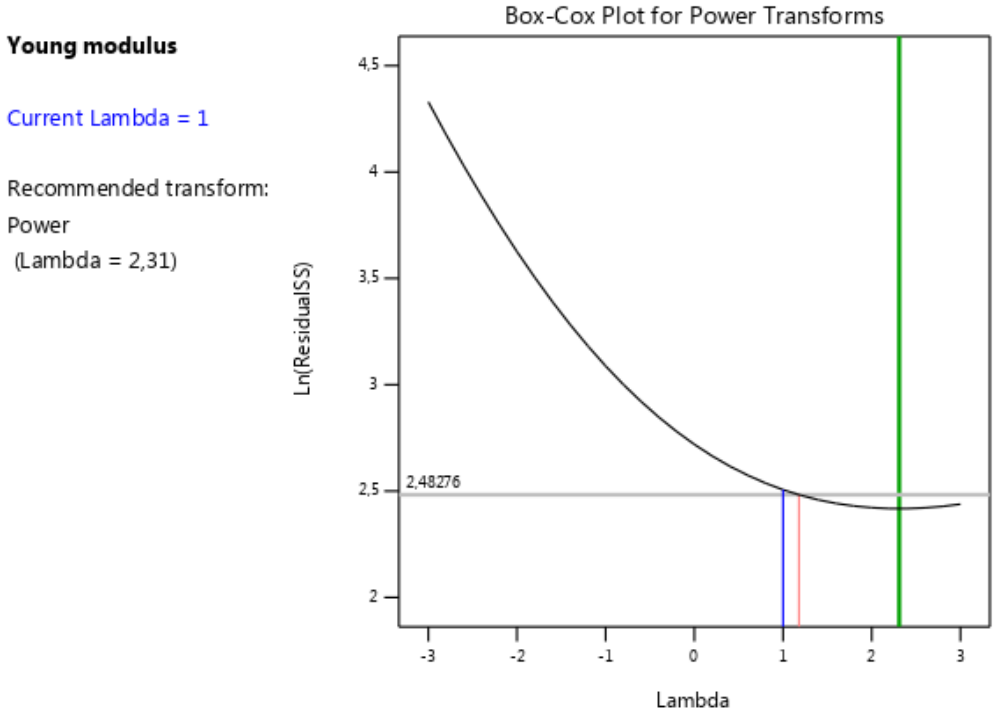
F vrijednost modela od 5,74 ukazuje na značajnost modela jer vjerojatnost da se pojavi vrijednost uslijed šuma iznosi manje od 0,06%. F vrijednost veličine odstupanja od modela od 0,8196 znači da ova veličina nije značajna u odnosu na čistu pogrešku. Postoji vjerojatnost od 70% da F vrijednost veličine odstupanja od modela nastaje od šuma. Tablica 13 prikazuje osnovne statističke parametre modela.

Tablica 13. Statistički parametri modela

Standardna devijacija	0,4559
Aritmetička sredina	2,92
Koeficijent varijacije %	15,61
Koeficijent determinacije - R^2	0,2803
Prilagođeni koeficijent determinacije - R^2_{adj}	0,2315
Predviđeni koeficijent determinacije - R^2_{pred}	0,1532
Adekvatna preciznost	7,1052

Razlika između prilagođenog koeficijenta determinacije i predviđenog koeficijenta determinacije je manja od 0,2. Adekvatna preciznost je 7,1052 što je veće od 4.

Pod dijagnostikom testiramo valjanost rezultata pomoću dijagrama. U Box Cox dijagramu [Slika 30] lambda je različit od 1 pa je potrebna transformacija. Preporučena transformacija je transformacija potenciranjem (eng. Power transformation).



Slika 30. Box-Cox dijagram

Nova značajnost modela i članova polinoma određivana je analizom varijance prikazanom u tablici 14.

Tablica 14. Rezultati analize varijance

Izvor varijabilnosti	Suma kvadrata odstupanja SS	Stupnjevi slobode df	Srednji kvadrat odstupanja S^2	Varijabla F	Rizik odbacivanja hipoteze p	Značajnost
Model	350,45	4	87,61	5,47	0,0008	Značajan
C	5,36	1	5,36	0,3343	0,5654	
D	84,69	1	84,69	5,28	0,0251	
E	193,32	1	193,32	12,06	0,0010	
CD	67,08	1	67,08	4,19	0,0452	
Ostatak	945,56	59	16,03			
Odstupanje od modela	419,91	27	15,55	0,9468	0,5542	Neznačajan
Čista pogreška	525,65	32	16,43			
Ukupno	1296,01	63				

F vrijednost modela od 5,74 ukazuje na značajnost modela jer vjerojatnost da se pojavi vrijednost uslijed šuma iznosi manje od 0,08%. F vrijednost veličine odstupanja od modela od 0,9468 znači da ova veličina nije značajna u odnosu na čistu pogrešku. Postoji vjerojatnost od 55% da F vrijednost veličine odstupanja od modela nastaje od šuma.

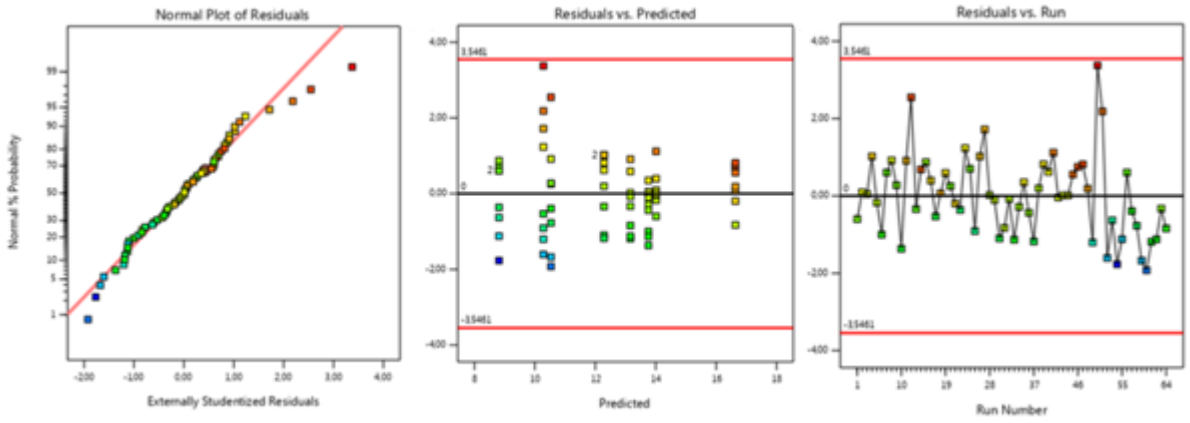
U tablici 15 prikazani su novi osnovni statistički parametri modela.

Tablica 15. Statistički parametri modela

Standardna devijacija	4,00
Aritmetička sredina	12,44
Koeficijent varijacije %	32,19
Koeficijent determinacije - R^2	0,2704
Prilagođeni koeficijent determinacije - R^2_{adj}	0,2209
Predviđeni koeficijent determinacije - R^2_{pred}	0,1415
Adekvatna preciznost	6,9925

Razlika između prilagođenog koeficijenta determinacije i predviđenog koeficijenta determinacije je manja od 0,2. Adekvatna preciznost je 6,9925 što je veće od 4.

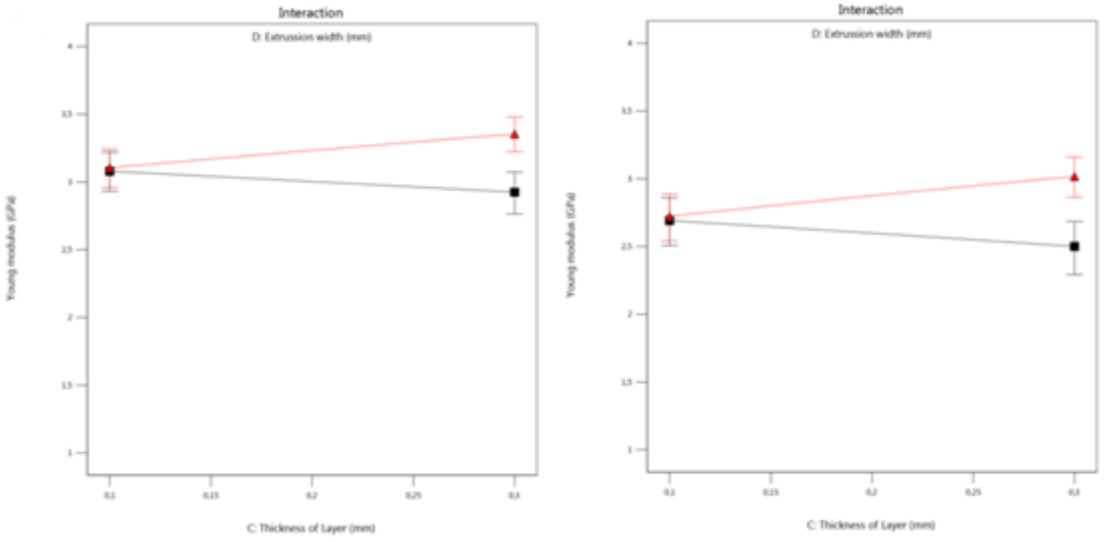
Iz normaliziranog papir vjerojatnosti (Slika 31a) točke prate liniju što ukazuje na normalnu distribuciju. Kod slučajnog rasipanja ostataka u odnosu na (predviđene)vrijednosti za rezultate (Slika 31b) i slučajnog rasipanja ostataka u odnosu na redoslijed izvođenja pokusa (Slika 31c) točke su unutar granica te nema uočljivog trenda.



a) b) c)

Slika 31. a) Normalizirani papir vjerojatnosti ostataka, b) Slučajno rasipanje ostataka u odnosu na (predviđene)vrijednosti za rezultate, c) slučajno rasipanje ostataka u odnosu na redoslijed izvođenja pokusa

Slika 32a i 32b prikazuje grafički prikaz međudjelovanja faktora širine ekstrudiranja i debljine sloja ovisno o pozicije test cijevi na Youngov modul. Iz grafa je vidljivo da za horizontalnu poziciju dobivamo veće iznose Youngovog modula. Crna linija predstavlja nižu razinu širine ekstrudiranja dok crvena višu. Za višu razinu širine ekstrudiranja dobivamo veće iznose Youngovog modula.

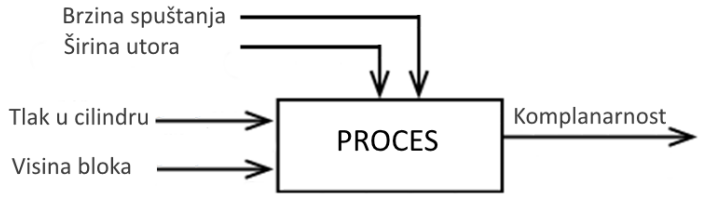


a) b)

Slika 32. Grafički prikaz međudjelovanja faktora D i C na Youngov modul za a) horizontalnu b) vertikalnu poziciju cijevi

4.2. Primjer metode odzivne površine: Poboljšanje kvalitete terminala slušalice pomoću sekvencijalnog plana pokusa [7]

U ovom članku sekvencijalnim pristupom, prvo potpunim faktorskim planom pokusa pronađeni su važni faktori te se zatim pomoću metode odzivne površine minimizirala komplanarnost terminala slušalica čime se poboljšala kvaliteta proizvoda. Velika komplanarnost terminala stvarala je jeku u slušalicama. Na komplanarnost najviše utječu uvjeti rada stroja za zakivanje. Faktori su tlak u cilindru, visina bloka, brzina spuštanja i širina utora. Rezultat prve faze pokusa pokazao je da visok tlak i niža visina bloka mogu uzrokovati nižu komplanarnost. Slika 33 prikazuje model procesa i kako faktori utječu na njega. Tablica 16 prikazuje razine faktora za metodu odzivne površine.



Slika 33. Model procesa terminala slušalice

Tablica 16. Faktori i njihove razine procesa terminala slušalice

Faktori	Razine
Tlak u cilindru, Pa	6 - 8
Visina bloka, mm	13,1 - 13,7

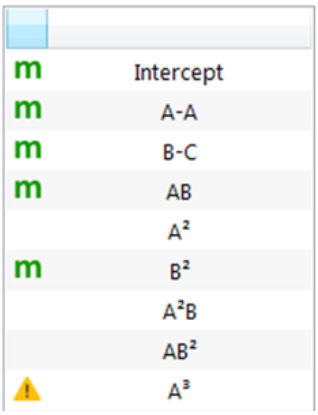
Plošno centriran centralno kompozitni plan je korišten u drugoj fazi pokusa. Pokus se sastoji od četiri faktorske točke, pet centralnih točka i četiri aksijalne točke. Matrica za pokus dobivena je pomoću Design Expert 13 programa i prikazana je u tablici 17 zajedno sa odzivom Y koji predstavlja komplanarnost u milimetrima. Redoslijed stanja pokusa je slučajan kako bi se zadovoljila stohastika.

Tablica 17. Vrijednosti faktora te izmjerene vrijednosti komplanarnosti

Stanje pokusa	Tlak u cilindru - A	Visina bloka - B	Komplanarnost - Y
1	7	13,4	0,029
2	6	13,1	0,031
3	7	13,4	0,024
4	6	13,7	0,033
5	7	13,7	0,036
6	8	13,7	0,039
7	7	13,4	0,029
8	8	13,4	0,022
9	7	13,4	0,027

10	7	13,1	0,022
11	8	13,1	0,018
12	7	13,4	0,027
13	6	13,4	0,030

Eliminacijom unatrag odbacujemo članove kojima vrijednost veća od 0,05. Nakon eliminacije dobivamo model prikazan slikom 13. Značajni članovi uključeni u model su A, B, AB i B^2.



Slika 34. Članovi koji ulaze u model

Tablica 18 prikazuje rezultate analize varijance. Vrijednost F modela od 25,83 znači da je model značajan, postoji samo 0,01% vjerojatnosti da se tako velika F vrijednost pojavi uslijed šuma. P vrijednosti manje od 0,05 ukazuju da je model značajan, u ovom slučaju A,B,AB i B2 su značajni članovi modela. Odstupanje od modela od 0,77 ukazuje da nije značajno relativno čistoj pogrešci. Postoji 59,59% vjerojatnosti da odstupanje od modela je tako veliko zbog šuma.

Tablica 18. Tablica analize varijance

Izvor varijabilnosti	Suma kvadrata odstupanja SS	Stupnjevi slobode df	Srednji kvadrat odstupanja S^2	Varijabla F	Rizik odbacivanja hipoteze p	Značajnost
Model	0,0004	4	0,0001	25,83	0,0001	Značajan
A	0,0000	1	0,0000	10,08	0,0131	
B	0,0002	1	0,0002	61,31	<0,0001	
AB	0,0001	1	0,0001	24,25	0,0012	
B^2	0,0000	1	0,0000	7,69	0,0242	
Ostatak	0,0000	8	3,722E-06			
Odstupanje od modela	0,0000	4	3,243E-06	0,7723	0,5959	Neznačajan
Čista pogreška	0,0000	4	4,200E-06			
Ukupno	0,0004	12				

Tablica 19 prikazuje statističke podatke o modelu. Predviđeni koeficijent determinacije je 0,7570, a prilagođeni koeficijent determinacije je 0,8922 te je njihova razlika manja od 0,2. Vrijednost adekvatne preciznosti je 18,2488 što je značajno veće od 4.

Tablica 19. Statistički parametri modela

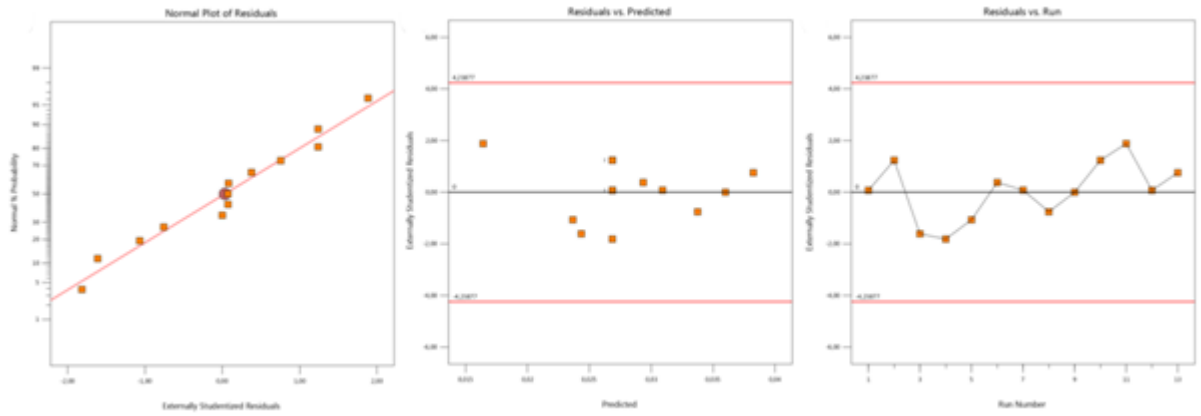
Standardna devijacija	0,0019
Aritmetička sredina	0,0282
Koeficijent varijacije %	6,83
Koeficijent determinacije - R^2	0,9281
Prilagođeni koeficijent determinacije - R^2_{adj}	0,8922
Predviđeni koeficijent determinacije - R^2_{pred}	0,7570
Adekvatna preciznost	18,2488

Predviđanje koeficijenta predstavlja očekivanu promjenu odziva po jedinici promjene u vrijednosti faktora kada su svi preostali faktori držani konstantnima (Tablica 20).

Tablica 20. Koeficijenti u kodiranim faktorima

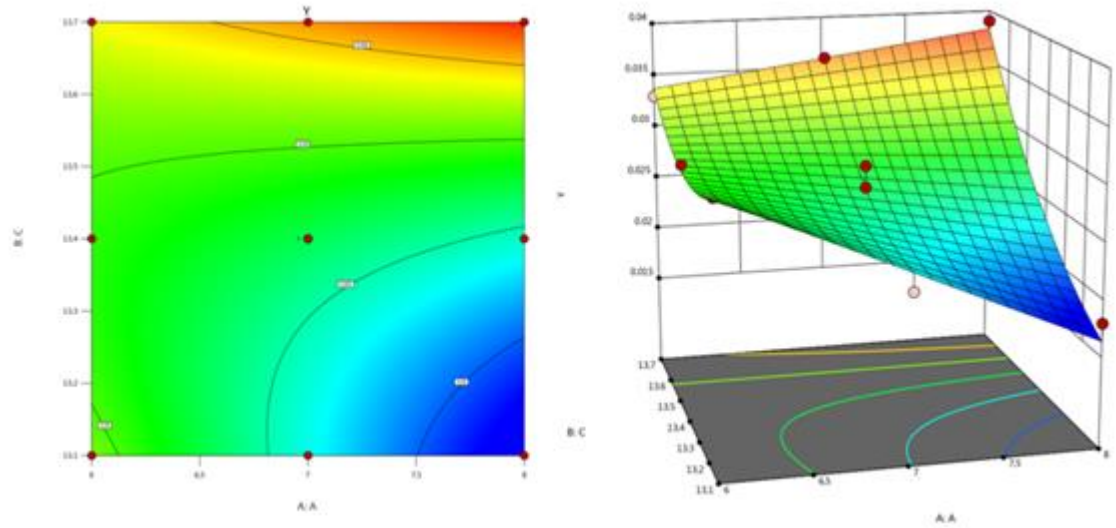
Faktor	Predviđanje koeficijenta	Stupnjevi slobode	Standardna pogreška	95% CI Niži	95% CI Viši
Interecept	0,0269	1	0,0007	0,0252	0,0285
A	-0,0025	1	0,0008	-0,0043	-0,0007
B	0,0062	1	0,0008	0,0044	0,0080
AB	0,0048	1	0,0010	0,0025	0,0070
B^2	0,0030	1	0,0011	0,0005	0,0055

Normalnost izmjerenih vrijednosti za pojedina stanja pokusa ispituje se normaliziranim papirom vjerojatnosti ostataka (Slika 35a). Točke prate ravnu liniju što ukazuje na to da ostaci prate normalnu raspodjelu. Slučajno rasipanje ostataka u odnosu na modelom izračunate vrijednosti i slučajno rasipanje ostataka u odnosu na redoslijed izvođenja pokusa ima normalnu razdiobu bez članova izvan granica. Slika 36 prikazuje konturni dijagram i 3D prikaz odzivne površine.



a) b) c)

Slika 35. a) Normaliziranim papirom vjerojatnosti ostataka, b) Slučajno rasipanje ostataka u odnosu na modelom izračunate vrijednosti, c) Slučajno rasipanje ostataka u odnosu na redoslijed izvođenja pokusa

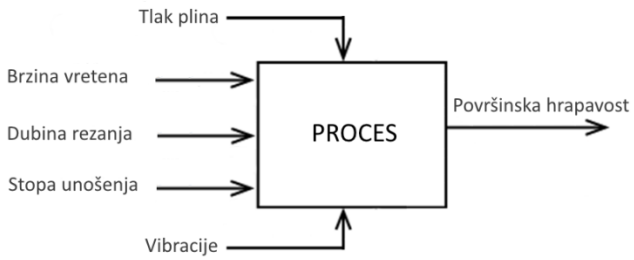


a) b)

Slika 36. a) Konturni dijagram, b) 3D prikaz odzivne površine

4.3. Primjer Taguchijevog plana pokusa: Poboljšanje kvalitete površine strojne obrade saća aluminija postupkom fiksiranja ledom [8]

Članak se bavi optimiziranjem parametara strojne obrade saća aluminija kako bi dobili bolju površinsku hrapavost i površinsku morfologiju u postupku fiksiranja saća ledom. Za razliku od ostalih metoda punjenjem između saća led se lakše čisti i ne zagađuje okoliš. Led se održava pomoću tekućeg dušika. Slika 37 prikazuje faktore u modelu procesa strojne obrade saće i kako oni utječu na njega. Tablica 21 prikazuje faktore i njihove razine.



Slika 37. Model procesa strojne obrade saća

Tablica 21. Razine i vrijednosti faktora u procesu strojne obrade saća

Faktor	Razina 1	Razina 2	Razina 3	Razina 4
Brzina vretena, o/min	2000	3000	4000	5000
Dubina rezanja, mm	0,4	0,8	1,2	1,6
Stopa unošenja, mm/min	50	100	150	200

Pokus ima tri faktora na 4 razine, zbog toga broj stupnjeva slobode mora biti minimalno 9 (3*3). Pomoću programa Minitab 19 je odabran Taguchi $L_{16}(4^3)$ prikazan u tablici 22.

Tablica 22. Taguchijev L_{16} ortogononalni pokus

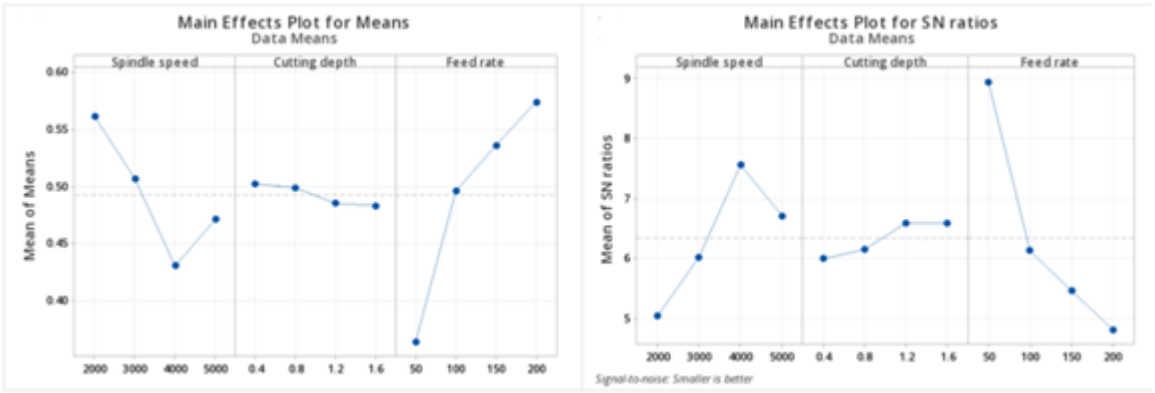
Broj pokusa	Brzina vretena	Dubina rezanaja	Stopa unošenja
1	2000	0,4	50
2	2000	0,8	100
3	2000	1,2	150
4	2000	1,6	200
5	3000	0,4	100
6	3000	0,8	50
7	3000	1,2	200
8	3000	1,6	150
9	4000	0,4	150
10	4000	0,8	200
11	4000	1,2	50
12	4000	1,6	100
13	5000	0,4	200
14	5000	0,8	150
15	5000	1,2	100
16	5000	1,6	50

Tablica 23 prikazuje izmjereni odziv i izračunati S/N omjer. S/N omjer je izračunat prema "manje je bolje" modelu jer svrha eksperimenta je naći minimalnu vrijednost površinske hrapavosti.

Tablica 23. Taguchijev L_{16} ortogononalni pokus sa odzivom i S/N omjerom

Broj pokusa	Brzina vretena (o/min)	Dubina rezanja (mm)	Stopa unošenja (mm/min)	R_a (μm)	S/N omjer (dB)
1	2000	0,4	50	0,480	6,3752
2	2000	0,8	100	0,552	5,1612
3	2000	1,2	150	0,602	4,4081
4	2000	1,6	200	0,612	4,2650
5	3000	0,4	100	0,519	5,6967
6	3000	0,8	50	0,368	8,6830
7	3000	1,2	200	0,555	5,1141
8	3000	1,6	150	0,586	4,6420
9	4000	0,4	150	0,450	6,9357
10	4000	0,8	200	0,569	4,8978
11	4000	1,2	50	0,288	10,8122
12	4000	1,6	100	0,416	7,6181
13	5000	0,4	200	0,561	5,0207
14	5000	0,8	150	0,507	5,8998
15	5000	1,2	100	0,497	6,0729
16	5000	1,6	50	0,320	9,8970

Dijagram glavnih efekata za srednju vrijednost i omjer signal šum, tri faktora pokusa strojne obrade prikazan je na slici 38. Dijagram glavnih efekata prikazuje utjecaj svakog faktora na rezultat pokusa. U dijagramu je vidljivo da razine faktora koje će osigurati da postupak neće odstupati su razina 3 brzine vretena(4000 o/min) i razina 1 stopa unošenja (50mm/min), dok dubina rezanja ima mali efekt na rezultat.



a) b)

Slika 38. Dijagram glavnih efekata za a) srednju vrijednost, b) omjer signal šum

Tablica odziva za omjer signal šum prikazuje kojim redoslijedom faktori utječu na odziv. Stopa unošenja najviše utječe zatim brzina vretena te dubina rezanja (Tablica 24).

Tablica 24. Odziv signal šum

Razina	Brzina vretena	Dubina rezanja	Stopa unošenja
1	5,052	6,007	8,942
2	6,034	6,160	6,137
3	7,566	6,602	5,471
4	6,723	6,606	4,824
Delta	2,514	0,598	4,117
Rank	2	3	1

5. EXPERIMENTALNI DIO

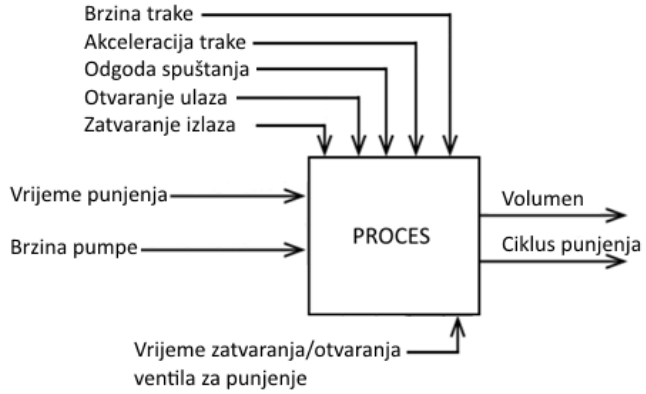
Eksperimentalni dio proveden je na poluautomatskoj liniji za punjenje aditivom u 5 l spremnike (Slika 39). Cilj eksperimenta bio je odrediti optimalne vrijednosti faktora brzine pumpe i vremena punjenja s kojim se postiže točno određena količina punjenja uz što kraći ciklus punjenja.

Osnovni dijelovi linije su: postolje na kojem su transportna traka, cilindar s diznom za punjenje, glava za čepljenje, pumpa za doziranje (nalazi se unutar postolja stroja) i upravljački panel. Pumpa za punjenje spojena je na 1000 l IBC kontejner u kojem se nalazi medij za punjenje. Za testiranje korištena je voda temperature 20°C. S vagom Dini Argeo TRD6500 kontrolirana je količina punjenja, a vrijeme ciklusa mjereno je između dva uzastopna punjenja.



Slika 39. Linija za polu automatsko punjenje

Slika 40 prikazuje model procesa uz pripadajuće faktore.



Slika 40. Model procesa punjenja spremnika

Primijenjen je centralno kompozitni plan (CCD). Dva promatrana faktora proučavana su na pet odabranih razina (Tablica 25). Pokus se sastoji od četiri faktorske točke, pet centralnih točka i četiri aksijalne točke što daje ukupno trinaest točaka pokusa.

Tablica 25. Faktori i njihove razine

Faktori	Oznaka faktora	Kodirana razina				
		-α	-1	0	1	α
Brzina pumpe (Hz)	A	25,9	30	40	50	54,1
Vrijeme punjenja (ms)	B	2586	3000	4000	5000	5414

Pokus je generiran u programu Design Expert 13 te je rezultantna matrica prikazana u tablici 26. Pokus je repliciran 3 puta što je rezultiralo ukupno s 52 točke pokusa.

Tablica 26. Rezultantna matrica s odzivima volumenom i trajanjem ciklusa

Std	Run	Brzina	Vrijeme	Volumen	Ciklus
9	1	40	4000	4827	10,41
11	2	40	4000	4937	10,12
12	3	40	4000	4804	10,02
10	4	40	4000	4854	10,17
6	5	54,1	4000	6307	10,06
13	6	40	4000	4908	10,03
1	7	30	3000	2606	9,6
5	8	25,9	4000	3047	9,89
4	9	50	5000	7643	10,95
7	10	40	2586	2963	8,47
2	11	50	3000	4246	8,95
8	12	40	5414	6695	11,44
3	13	30	5000	4592	11,02
14	14	30	3000	2631	8,9
15	15	50	3000	4203	9,04
16	16	30	5000	4665	10,96
17	17	50	5000	7626	11,02
18	18	25,9	4000	3039	9,92
19	19	54,1	4000	6191	10,1
20	20	40	2586	2970	8,49
21	21	40	5414	6703	11,31
22	22	40	4000	4992	10,02
23	23	40	4000	4845	10,02
24	24	40	4000	4968	10,03
25	25	40	4000	4798	10,12
26	26	40	4000	4865	10,4
27	27	30	3000	2603	9,2
28	28	50	3000	4277	8,95
29	29	30	5000	4648	10,94
30	30	50	5000	7538	11

31	31	25,9	4000	3126	9,88
32	32	54,1	4000	6371	9,91
33	33	40	2586	2988	8,88
34	34	40	5414	6833	11,31
35	35	40	4000	4872	10,06
36	36	40	4000	4885	10,12
37	37	40	4000	4835	10,14
38	38	40	4000	4887	10,23
39	39	40	4000	4826	10,4
40	40	30	3000	2681	9,4
41	41	50	3000	4405	8,91
42	42	30	5000	4610	11,14
43	43	50	5000	7589	11,36
44	44	25,9	4000	3095	10,12
45	45	54,1	4000	6324	10,23
46	46	40	2586	3023	8,94
47	47	40	5414	6781	11,57
48	48	40	4000	4917	10,42
49	49	40	4000	4836	10,37
50	50	40	4000	4893	10,32
51	51	40	4000	4915	10,41
52	52	40	4000	4896	10,37

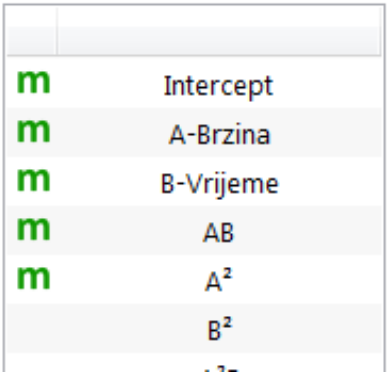
5.1. Analiza odziva volumena punjenja

Polinom najvišeg stupnja koji zadovoljava da je sekvencijska p vrijednost niža od 0,05 te da je odstupanje od modela više od 0,05 je kvadratni model (Tablica 27). Kubni model je združen što znači da se ne pretpostavljaju sve kubne komponente.

Tablica 27. Sažetak prikladnosti modela

	Sekvencijska p vrijednost	Odstupanje od modela p vrijednost	Prilagođeni koeficijent determinacije	Predviđeni koeficijent determinacije	
Linearni	<0,0001	<0,0001	0,9782	0,9754	
2FI	<0,0001	<0,0001	0,9961	0,9957	
Kvadratni	**<0,0001**	**0,8828**	**0,9986**	**0,9984**	Predložen
Kubni	0,7710	0,7068	0,9985	0,9982	Združen

Eliminacijom odbacuju se članovi kojima je vrijednost veća od 0,05. Nakon eliminacije dobivamo model prikazan na slici 41. Značajni članovi koji su uključeni u model su A, B, AB i A^2.



Slika 41. Članovi modela

Tablica 28 prikazuje rezultate analize varijance. Vrijednost F modela od 9241,57 znači da je model značajan, postoji samo 0,01% vjerojatnosti da se tako velika F vrijednost pojavi uslijed šuma. P vrijednosti manje od 0,05 ukazuju da je model značajan, u ovom slučaju A,B,AB i A2 su značajni članovi modela. Odstupanje od modela od 0,1782 ukazuje da nije značajno relativno čistoj pogrešci. Postoji 94,84% vjerojatnosti da odstupanje od modela je tako veliko zbog šuma.

Tablica 28. Rezultati analize varijance

Izvor varijabilnosti	Suma kvadrata odstupanja SS	Stupnjevi slobode df	Srednji kvadrat odstupanja S^2	Varijabla F	Rizik odbacivanja hipoteze p	Značajnost
Model	1,007E+08	4	2,518E+07	9241,57	<0,0001	Značajan
A	4,212E+07	1	4,212E+07	15458,39	<0,0001	
B	5,663E+07	1	5,663E+07	20780,37	<0,0001	
AB	1,736E+06	1	1,736E+06	637,23	<0,0001	
A^2	2,461E+05	1	2,461E+05	90,30	<0,0001	
Ostatak	1,281E+05	47	2725,03			
Odstupanje od modela	2088,49	4	522,12	0,1782	0,9484	Neznačajan
Čista pogreška	1,260E+05	43	2929,95			
Ukupno	1,009E+08	51				

Tablica 29 prikazuje statističke podatke o modelu. Predviđeni koeficijent determinacije je 0,9984, a prilagođeni koeficijent determinacije je 0,9986 te je njihova razlika manja od 0,2. Vrijednost adekvatne preciznosti je 306,3446 što je značajno veće od 4.

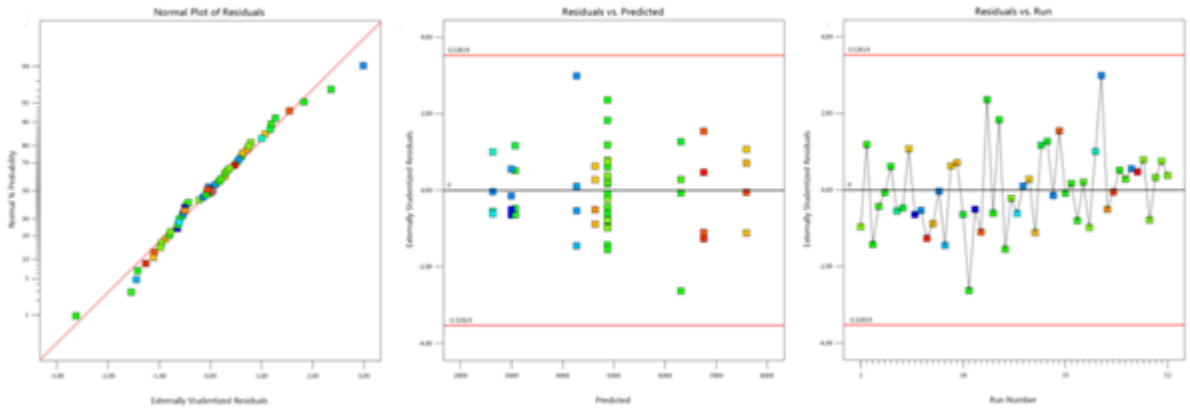
Tablica 29. Statistički parametri modela

Standardna devijacija	52,20
Aritmetička sredina	4818,83
Koeficijent varijacije %	1,08
Koeficijent determinacije - R^2	0,9987
Prilagođeni koeficijent determinacije - R^2_{adj}	0,9986
Predviđeni koeficijent determinacije - R^2_{pred}	0,9984
Adekvatna preciznost	306,3446

Konačna jednadžba sa kodiranim faktorima jednaka je jednadžbi:

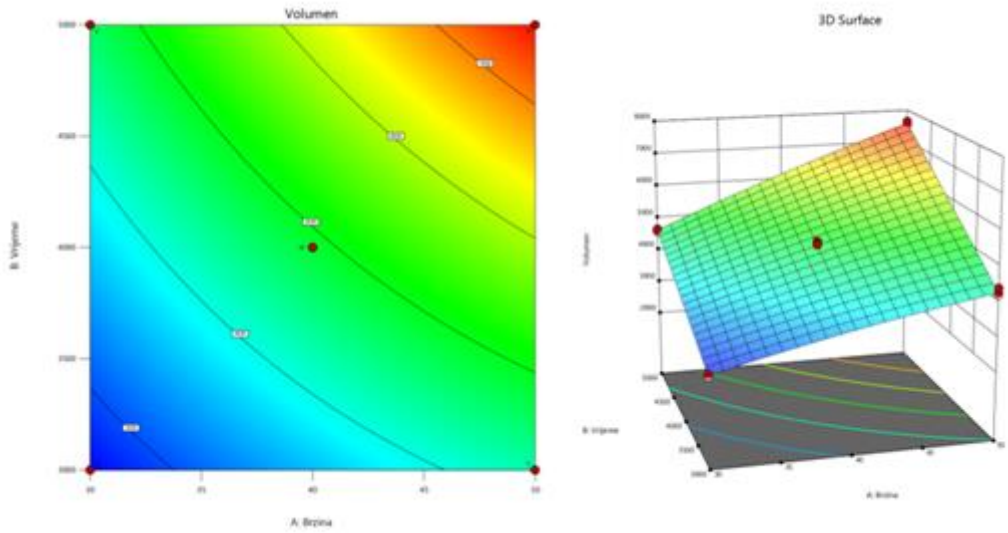
$$Volumen = 4876{,}30 + 1149{,}05A + 1330{,}36B + 329{,}44AB - 93{,}67A^2$$

Normalnost izmjerenih vrijednosti za pojedina stanja pokusa ispituje se normaliziranim papirom vjerojatnosti ostataka (Slika 42a). Točke prate ravnu liniju što ukazuje na to da ostaci prate normalnu raspodjelu. Slučajno rasipanje ostataka u odnosu na modelom izračunate vrijednosti (Slika 42b) i slučajno rasipanje ostataka u odnosu na redoslijed izvođenja pokusa (Slika 42c) ima normalnu razdiobu bez članova izvan granica. Konturni dijagram je prikazan slici 43a, dok je 3D prikaz odzivne površine slikom 43b.



a) b) c)

Slika 42. a) Normalizirani papir vjerojatnosti ostataka, b) Slučajno rasipanje ostataka u odnosu na modelom izračunate vrijednosti, c) Slučajno rasipanje ostataka u odnosu na redoslijed izvođenja pokusa



a) b)

Slika 43. a) Konturni dijagram, b) 3D prikaz odzivne površine

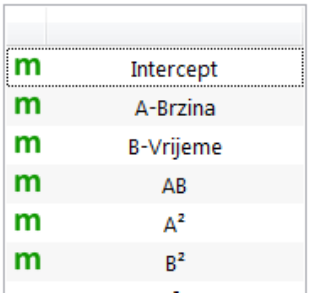
5.2. Analiza ciklusa

Polinom najvišeg stupnja koji zadovoljava uvijete je kvadratni (Tablica 30).

Tablica 30. Sažetak prikladnosti modela

Izvor	Sekvencijska P vrijednost	Odstupanje od modela p vrijednost	Prilagođeni koeficijent determinacije	Predviđeni koeficijent determinacije	
Linear	<0,0001	0,0114	0,9418	0,9367	
2FI	0,0434	0,0287	0,9454	0,9395	
Kvadratni	0,0113	0,2913	0,9532	0,9453	Predložen
Kubni	0,2218	0,3887	0,9543	0,9436	Združen

Eliminacijom odbacujemo članove kojima vrijednost veća od 0,05. Nakon eliminacije dobivamo model prikazan (Slika 44). Značajni članovi uključeni u model su A, B, AB, A^2 i B^2.



Slika 44. Članovi modela

Tablica 31 prikazuje rezultate analize varijance. Vrijednost F modela od 208,56 znači da je model značajan, postoji samo 0,01% vjerojatnosti da se tako velika F vrijednost pojavi uslijed šuma. P vrijednosti manje od 0,05 ukazuju da je model značajan, u ovom slučaju A,B,AB i A2 su značajni članovi modela. Odstupanje od modela od 1,29 ukazuje da nije značajno relativno čistoj pogrešci. Postoji 29,13% vjerojatnosti da odstupanje od modela je tako veliko zbog šuma.

Tablica 31. Rezultati analize varijance

Izvor varijabilnosti	Suma kvadrata odstupanja SS	Stupnjevi slobode df	Srednji kvadrat odstupanja S^2	Varijabla F	Rizik odbacivanja hipoteze p	Značajnost
Model	30,05	5	6,01	208,56	<0,0001	Značajan
A	0,0026	1	0,0026	0,0909	0,7644	
B	29,61	1	29,61	1027,81	<0,0001	
AB	0,1444	1	0,1444	5,01	0,0301	
A^2	0,1997	1	0,1997	6,93	0,0115	
B^2	0,1210	1	0,1210	4,20	0,0462	
Ostatak	1,33	46	0,0288			
Odstupanje od modela	0,1091	3	0,0364	1,29	0,2913	Neznačajan
Čista pogreška	1,22	43	0,0283			
Ukupno	31,37	51				

Tablica 32 prikazuje statističke podatke o modelu. Predviđeni koeficijent determinacije je 0,9453, a prilagođeni koeficijent determinacije je 0,9532 te je njihova razlika manja od 0,2. Vrijednost adekvatne preciznosti je 47,19 što je veće od 4.

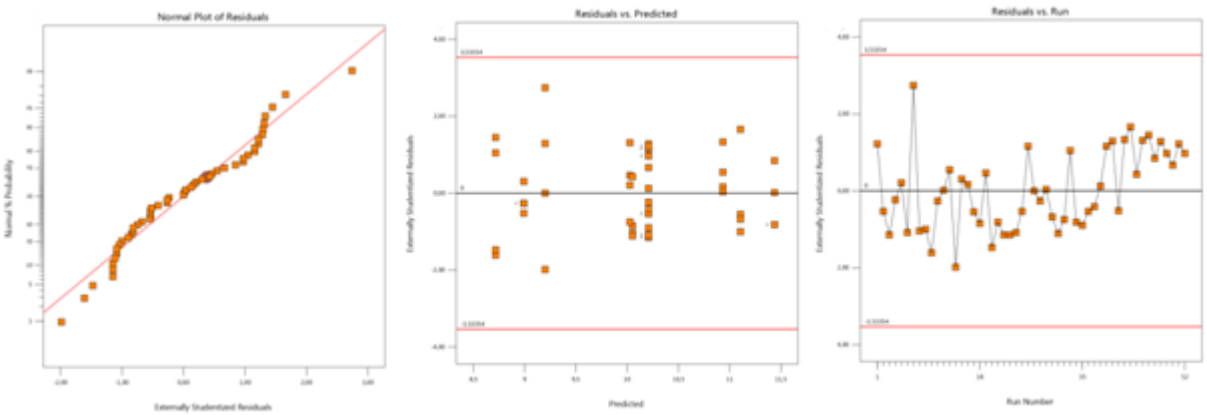
Tablica 32. Statistički parametri modela

Standardna devijacija	0,1697
Aritmetička sredina	10,12
Koeficijent varijacije %	1,68
Koeficijent determinacije - R^2	0,9578
Prilagođeni koeficijent determinacije - R^2_{adj}	0,9532
Predviđeni koeficijent determinacije - R^2_{pred}	0,9453
Adekvatna preciznost	47,1866

Konačna jednadžba sa kodiranim faktorima jednaka je jednadžbi:

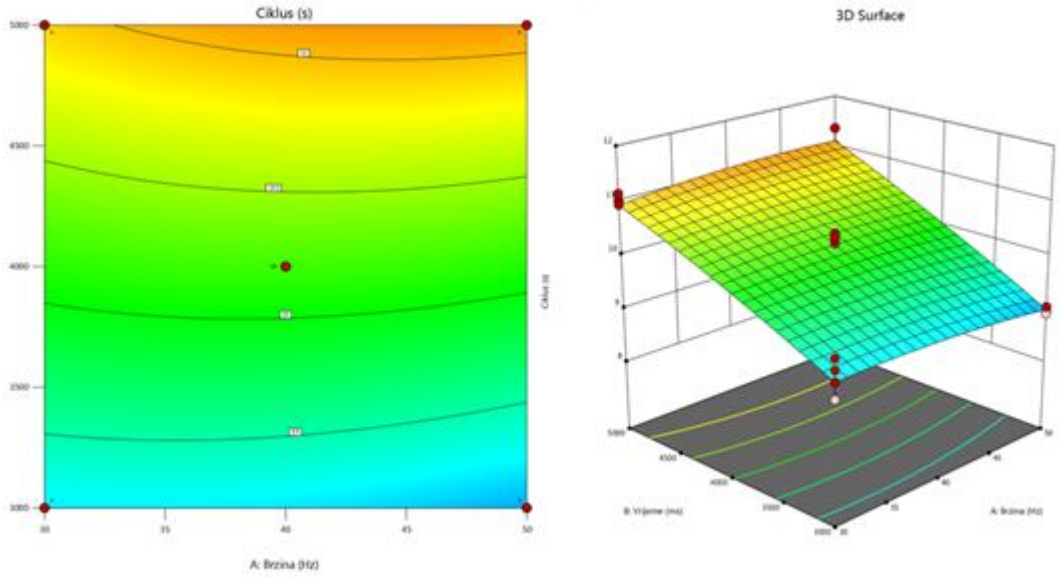
$$Ciklus = 10{,}21 - 0{,}0091A + 0{,}9621B + 0{,}095AB - 0{,}0851A^2 - 0{,}0659B^2$$

Normalnost izmjerenih vrijednosti za pojedina stanja pokusa ispituje se normaliziranim papirom vjerojatnosti ostataka (Slika 45a). Točke prate ravnu liniju što ukazuje na to da ostaci prate normalnu raspodjelu. Slučajno rasipanje ostataka u odnosu na modelom izračunate vrijednosti (Slika 45b) i slučajno rasipanje ostataka u odnosu na redoslijed izvođenja pokusa (Slika 45c) ima normalnu razdiobu bez članova izvan granica. Konturni dijagram je prikazan na slici 46a dok je 3D prikaz odzivne površine slikom 46b.



a) b) c)

Slika 45. a) Normalizirani papir vjerojatnosti ostataka, b) Slučajno rasipanje ostataka u odnosu na modelom izračunate vrijednosti, c) Slučajno rasipanje ostataka u odnosu na redoslijed izvođenja pokusa



a) b)

Slika 46. a) Konturni dijagram, b) 3D prikaz odzivne površine

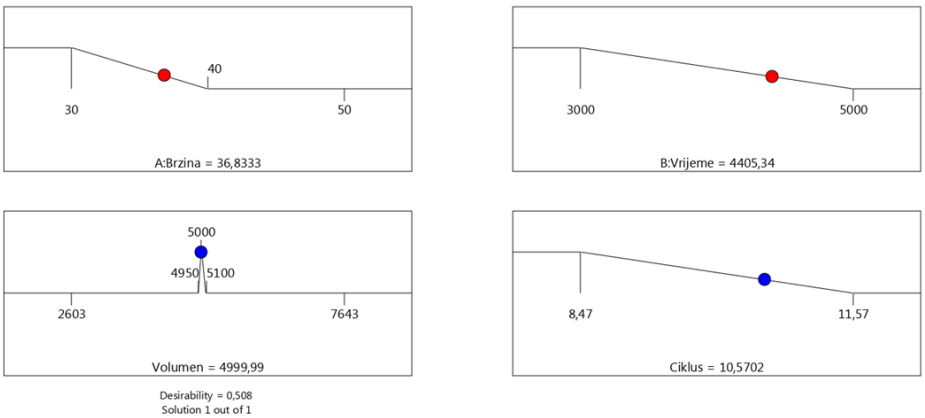
5.3. Optimizacija

Nakon modeliranja i analize provedena je numerička optimizacija. Kriterij brzina pumpe se minimizira iz razloga što pri većim brzinama može doći do neželjene pojave "zapljuskivanja". Vrijeme punjenja se minimizira kako bi se postiglo manje taktno vrijeme. Ciljana vrijednost za volumen je 5000 ml u rasponu od 4950 ml (propisano minimalno) do 5100 ml. (maksimalni volumen boce). Ciklus punjenja se minimizira kako bi ukupno dobili što kraće punjenje. Kriteriji optimizacije prikazani su u tablici 33. Težinska vrijednost kriterija je relativna važnost jednog cilja nasuprot drugome, varira od najmanje važne značajke 1 do najvažnije značajke 5.

Tablica 33. Sažetak kriterija optimizacije

	Faktor 1	Faktor 2	Odziv 1	Odziv 2
	Brzina pumpe	Vrijeme punjenja	Volumen	Ciklus punjenja
Cilj	Minimizirati	Minimizirati	Ciljana vrijednost 5000 ml	Minimizirati
Važnost	2	2	5	3

Primjenom optimizacije funkcije poželjnosti dobiveno je jedno rješenje. Grafički prikaz optimalnog rješenja je „Ramp“ prikaz (Slika 47). Optimalne postavke faktora prikazane su crvenim točkama. U tablici 34 prikazani su podaci dobiveni preko „Ramp“ prikaza.

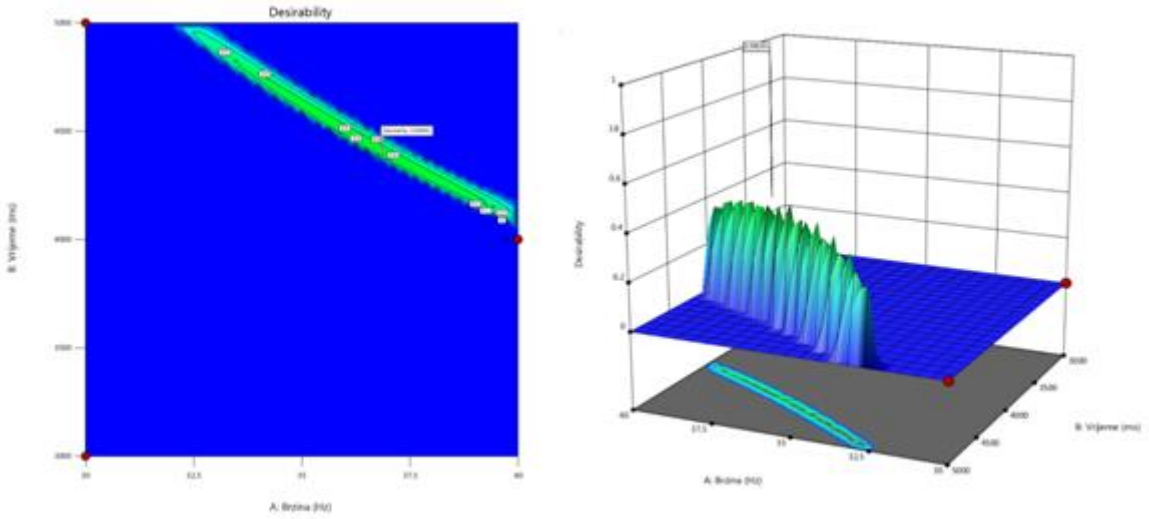


Slika 47. „Ramp“ prikaz

Tablica 34. Optimalna vrijednost za zadane uvjete

	Faktor 1	Faktor 2	Odziv 1	Odziv 2
Optimalna vrijednost	Brzina pumpe	Vrijeme punjenja	Volumen	Ciklus punjenja
	36,83 Hz	4405 ms	5000 ml	10,57s

Poželjnost (eng. Desirability) nije statistički nego numerički alat za vrednovanje koliko su zadani ciljevi postignuti. Što su bliži svi ciljevi to je ukupna poželjnost veća. Poželjnost od 1 nam ukazuje da smo postigli sve ciljeve, dok poželjnost od 0 se dobiva kada jedan ili više odziva pada izvan granica. Slika prikazuje poželjnost u 2D (Slika 48a) i 3D (Slika 48b) obliku. Plavom bojom prikazana je poželjnost od nula.



a) b)

Slika 48. Rezultat numeričke optimizacije u: a) 2D i b) 3D prikazu

5.4. Post analiza

Konfirmacijski pokusi potrebni su kako bi potvrdili da dobiveni model može predvidjeti rezultate na optimalnim postavkama dobivenim analizom. Konfirmacijski pokus provodio se pri brzini pumpe od 36,8 Hz i trajanju punjenja od 4405 ms. Kako bi potvrdili adekvatnost modela, provedeno je osam izvedbi konfirmacijskih pokusa (Tablica 35).

Tablica 35. Izvedba konfirmacijskih pokusa

	Volumen	Ciklus
1	5027	10,59
2	5024	10,67
3	5054	10,80
4	5045	10,79
5	5041	10,73
6	5011	10,59
7	4981	10,51
8	5078	10,90

Interval predviđanja kaže da smo 95% sigurni da ćemo u sljedećoj izvedbi pri zadanim postavkama biti u zadanom intervalu. Očekivana vrijednost podataka (Tablica 36) nalazi se između niže i više vrijednosti intervala predviđanja.

Tablica 36. Podaci potvrde

	Predviđena srednja vrijednost	Predviđeni medijan	Std dev	n	SE pred	95% PI niža	Srednja vrijednost podataka	95 % PI viša
Volumen	4999,99	4999,99	52,2018	8	21,0708	4957,6	5032,63	5042,38
Ciklus	10,5701	10,5701	0,16975	8	0,07051	10,4281	10,6975	10,712

Rezultati ovakve analize primjenjivi su i za slučaj punjenja aditivom s obzirom da su karakteristike vrlo bliske eksperimentalnom mediju (voda). Nakon podešavanja parametara proizvodni proces punjenja spremnika postići će poželjne vrijednosti izlaznih karakteristika te osigurati izvrstan temelj za dodatne aktivnosti poboljšanja. Time se omogućuje kontinuirano poboljšanje što je danas nezaobilazna komponenta u strategiji svih ozbiljnih poduzeća.

6. ZAKLJUČAK

Ovim diplomskim radom željelo se ukazati na važnost uporabe planova pokusa u procesu poboljšanja kvalitete proizvoda i procesa. Opisani su najčešći modeli i pristupi problemu zadržavanja ili poboljšavanja kvalitete metodom planiranja i analize pokusa. Kod planiranja pokusa koristi se statistički pristup problemu i to pri izradi optimalnog plana pokusa, a potom nakon izvođenja pokusa obradom i analizom dobivenih rezultata. Samo dobro planiran pokus dovodi do zadanog cilja, te točne i odgovarajuće informacije. Cilj pokusa je odrediti faktore koji utječu na kvalitetu, pronaći optimalnu kombinaciju vrijednosti faktora, te dobiti informacije uz minimalni broj izvođenih eksperimenata.

Uz sam presjek metodologije u radu je prikazan i obrađen realni problem iz prakse – optimizacija linije punjenja. Primjenom metode planiranja i analize pokusa dobiveni su rezultati koji su iskorišteni u optimizaciji procesnih parametara. Korištenjem optimalnih procesnih parametara moguće je postići željenu količinu punjenja po spremniku uz minimalnu vjerojatnost nesukladnih jedinica. Također, smanjenje ciklusa pridonosi povećanju produktivnosti te posljedično i mogućnost povećanja kapaciteta proizvodnje. Time je opravdana svrha primijenjene metodologije.

Konačno, uporaba planova pokusa u procesu poboljšanja kvalitete ima veliki utjecaj na poboljšanje poslovanja, kao i na smanjenje troškova, što je osnovni cilj poslovanja svakog poduzeća.

LITERATURA

[1] Montgomery, DC. Design and Analysis of Experiments. USA: John Wiley & Sons, Inc.; 2019.

[2] Al-Ghamdi, K. Improving the practice of experimental design in manufacturing engineering , Doktorski rad, Birmingham: The University of Birmingham, 2011.

[3] Cornell, JA. Experiments with mixtures. USA: John Wiley & Sons, Inc.; 2002.

[4] Krishnaiah K, Shahabudeen P. Applied Design of Experiments and Taguchi Methods. India: PHI Learning Private Limited; 2012.

[5] Eguren JA, Esnaola A, Unzueta G. Modelling of an Additive 3D-Printing Process Based on Design of Experiments Methodology. 2020, doi: 10.12776/QIP.V24I1.1435

[6] Kolednjak, D. Utjecaj parametara zavarivanja na strukturu i svojstva čelika API 5L X80, Doktorski rad, Zagreb: Fakultet strojarstva i brodogradnje, 2014.

[7] He Z, Zhang X, Xie F, Zhang M. Earphone terminal quality improvement through sequential experimental design. 2015, doi: 10.1108/IJQRM-11-2013-0179

[8] Wang Y, Gan Y, Liu H, Han L, Wang J, Liu K. Surface Quality Improvement in Machining an Aluminum Honeycomb by Ice Fixation. 2020, doi:10.1186/s10033-020-00439-1