




UNIVERSITATEA POLITEHNICA DIN BUCUREȘTI



**Școala Doctorală de Electronică, Telecomunicații și
Tehnologia Informației**

Decizie nr. 779 din 03-12-2021

REZUMAT TEZĂ DE DOCTORAT

Ing. Elena-Diana GROSU-ȘANDRU

EVALUAREA VARIAȚIEI PROCESULUI DE FABRICAȚIE ÎN
ANALIZA PROIECTĂRII CIRCUITELOR BAZATĂ PE DATE,
UTILIZÂND MACHINE LEARNING

DATA-DRIVEN FABRICATION PROCESS VARIATION
ASSESSMENT IN CIRCUIT DESIGN ANALYSIS USING
MACHINE LEARNING

COMISIA DE DOCTORAT

Prof. Dr. Ing. Mihai CIUC Univ. Politehnica din București	President
Prof. Dr. Ing. Corneliu BURILEANU Univ. Politehnica din București	PhD Supervisor
Prof. Dr. Ing. Marina ȚOPA Univ. Tehnică din Cluj-Napoca	Referee
Prof. Dr. Rer. Mat. Georg PELZ Infineon Technologies AG & Univ. Duisburg-Essen	Referee
Prof. Dr. Ing. Cristian RAVARIU Univ. Politehnica din București	Referee

BUCUREȘTI 2022

Cuprins

1	Introducere	1
1.1	Impactul Variației Procesului asupra CI	1
1.1.1	Machine Learning în Industria Semiconductoarelor	1
1.2	Descrierea Problematicii	2
1.3	Motivația	2
1.4	Scopul Cercetării	3
1.5	Structura Tezei	3
2	Cercetări Conexe	4
2.1	Verificarea CI și Parametrii PCM	4
2.1.1	Verificarea Pre-Siliciu	4
2.1.2	Validarea Post-Siliciu	4
2.1.3	Testarea DoE și Testarea în Producție	5
2.1.4	Monitor de Control al Procesului (Process Control Monitor)	5
2.2	Analiza de Sensibilitate	5
2.2.1	Analiza de Sensibilitate Globală	5
2.2.2	Analiza de Sensibilitate Locală	5
3	Fundamente Teoretice	7
3.1	Algoritmi de Regresie	7
3.1.1	Învățare Supervizată	7
3.1.2	Dezvoltări Recente ale Algoritmilor de Regresie	8
3.2	Îmbunătățirea Modelului prin Selecția Caracteristicilor	8
3.3	Optimizarea Bayesiană (Bayesian Optimization)	8
4	Metodologia Verification for Manufacturability by Modelling Process Variation - Circuit Performance Dependency (P2P4M)	9
4.1	Fluxul Metodologiei	9
4.1.1	Cadrul General	9
4.1.2	Formularea Problemei și Fluxul Metodologiei P2P4M	9
4.2	Blocul de Selecție a Caracteristicilor	10
4.3	Antrenarea Modelului bazat pe Date preSi	11

4.4	Optimizarea Bayesiană (Bayesian Optimization) a Modelului Antrenat	11
4.5	Rezumatul Metodologiei P2P4M	11
4.6	Modelarea Distribuției postSi și Validarea Metodologiei	12
4.7	Aplicarea Metodologiei P2P4M	13
4.7.1	Unificarea Selecției Caracteristicilor și Optimizarea Bayesiană a Hiperparametrilor	13
4.7.2	Modelarea Dependentei Funcționale și Identificarea PCM Influenți	13
4.7.3	Modelarea și Validarea Distribuțiilor preSi și postSi	13
4.7.4	Fiabilitatea Metodologiei	14
5	Cazuri Particulare de Aplicare ale Metodologiei P2P4M	17
5.1	Cazul 1: Analiza de Sensibilitate cu Variația Procesului	18
5.1.1	Metodologia de Analiză de Sensibilitate Globală	18
5.1.2	Metodologia de Analiză de Sensibilitate Locală	18
5.1.3	Rezultate Experimentale	19
5.2	Cazul 2: Verificarea Modelului de Simulare	21
5.2.1	Fluxul Metodologiei	21
5.2.2	Rezultate Experimentale	22
5.3	Cazul 3: Predicția Randamentului	23
5.3.1	Metodologia de Predicție a Randamentului PreSi pentru Distribuțiile Normale	23
5.3.2	Metodologia de Predicție a Randamentului Parametric	24
5.3.3	Rezultate Experimentale	25
6	Concluzii	26
6.1	Obiective Generale și Rezultate	27
6.2	Contribuții Originale	28
6.3	Lista Publicațiilor Originale	30
6.4	Perspective de Dezvoltare Ulterioare	31
	Bibliografie	33

Capitolul 1

Introducere

Scopul general al acestei cercetări este de a dezvolta strategii, metodologii și instrumente care să evalueze impactul variației procesului asupra analizei proiectării circuitelor, prin corelarea realității unui circuit existent deja fabricat cu un nou design de CI, sporind astfel capacitatea producătorului de a crește producția.

1.1 Impactul Variației Procesului asupra CI

Variația procesului poate fi considerată o problemă veche pentru industriile de producție. În consecință, nu este un subiect nou pentru industria semiconducătorilor, fiind abordat de aproape 50 de ani [23] [21]. Variația procesului este definită ca abaterea parametrilor de la specificațiile lor nominale [18], fiind în același timp un proces complet aleatoriu. De obicei, aceasta apare în atributele tranzistoarelor, cum ar fi lungimile canalelor sau lățimile porților, care în general sunt mai ușor de controlat, sau în profilul și cantitatea de dopaj al substratului, sarcini care sunt mult mai greu de controlat. Variația procesului poate fi clasificată în variație sistematică și variație aleatorie [13], ambele fiind considerate la fel de importante. În plus, variația poate fi spațială sau temporală și poate apărea de la lot la lot, de la plachetă la plachetă, între matrițe sau în interiorul acestora. Această variație se poate traduce, de asemenea, în discrepanțe de performanță ale circuitului, aproape întotdeauna identificate ca scăderi. Cu toate acestea, performanțele circuitelor sunt afectate în mod diferit, în funcție de o serie de factori, de la logica circuitului până la implementarea acestuia. Prin urmare, pentru a reduce variația procesului și a limita efectele nedorite ale acestora, a fost introdus managementul variației de proces [18], aglutinând o serie de tehnici.

1.1.1 Machine Learning în Industria Semiconducătoarelor

Potențialul Învățării Automate (Machine Learning ML) în domeniul industriei semiconducătoarelor este foarte mare și poate aborda toate provocările legate de dezvoltare

și producție, începând cu proiectarea și terminând cu procesul de fabricație, ajutând la accelerarea timpului de dezvoltare al produselor [28], [27].

1.2 Descrierea Problematicii

Abateră introdusă de variația procesului în procesul nominal al parametrilor se traduce prin performanțe limitate ale circuitelor integrate, adică produsul de circuit integrat nu mai funcționează așa cum a fost conceput, ceea ce reprezintă o preocupare majoră. Parametrii de performanță ai circuitelor, cunoscuți și sub denumirea de Parametri Electrici (Electrical Parameters EP), sunt măsuri ale performanțelor circuitelor în condițiile unui set specific de condiții de funcționare. Aceștia sunt simulați în timpul verificării pre-siliciu (preSi) și măsurați în timpul validării post-siliciu (postSi), la diferite temperaturi. Parametrii monitorului de control al procesului (Process Control Monitor Parameters PCM), numiți și parametri tehnologici, reprezintă o măsură directă a gestionării variațiilor procesului în timpul producției, realizată pe câteva structuri înguste speciale, numite structuri de monitorizare a controlului procesului, situate printre matrițele de producție.

În prezent, este posibil să se coreleze EP cu PCM, care reprezintă o indicație a variației procesului, în timpul validării postSi, prin utilizarea loturilor de proiectare a experimentelor (Design of Experiments DoE). Cu toate acestea, analiza se realizează târziu, după etapele lungi, costisitoare și consumatoare de timp ale producției și testării. De asemenea, în postSi, numărul de măsurători ale fiecărui PCM pe o plachetă este mult mai mic decât numărul de măsurători disponibile pentru fiecare EP (câteva fața de mii), ceea ce face ca analiza să fie inexactă din cauza lipsei de corespondență 1-la-1 între cele două tipuri de parametri. În consecință, în procesele de producție din zilele noastre, există o cerere mare pentru o estimare precisă a relației dintre performanțele CI și variația procesului, încă de la începutul procesului de proiectare și de producție, deoarece aceasta ar reduce semnificativ timpul de comercializare și costurile totale ale produselor.

1.3 Motivația

Prima motivație a tezei este dezvoltarea unei metodologii capabile să prezică relația dintre performanțele circuitului și variația procesului (folosind parametrii tehnologici ca indicatori) într-o etapă incipientă, prin utilizarea alternativă a PCM. A doua motivație este legată de extragerea de cunoștințe noi și valoroase din datele de producție istorice, utilizând tehnici ML. Cea de-a treia motivație este corelată cu domeniile în care o astfel de relație ar putea fi utilă: diagnosticarea timpurie a răspunsurilor circuitelor care sunt sensibile la variația procesului, îmbunătățirea predicției randamentului și diagnosticarea inexactităților din modelul de simulare al dispozitivului. Cea de-a patra motivație este legată de alte probleme care pot fi abordate pe baza unei relații precoce între EP și PCM:

migrarea de la o fabrică la alta, efectul de aproximare al modelelor de dispozitive, planul DoE specific tehnologiei, analiza cauzelor fundamentale ale defectelor și verificarea modelului de CI cu variația procesului.

1.4 Scopul Cercetării

Obiectivul principal al acestei teze este de a dezvolta o metodologie cuprinzătoare pentru evaluarea exactă a impactului variației procesului asupra proiectării circuitelor, într-un stadiu incipient. Metodologia se bazează pe datele dobândite din diferite faze de verificare (simulări preSi și măsurători postSi) și urmărește să înțeleagă și să prevadă relația dintre parametrii tehnologici (ca indicatori pentru variațiile de proces) și parametrii de performanță ai circuitului. În primul rând, această teză introduce metodologia de modelare a dependențelor funcționale și statistice din faza inițială dintre performanțele circuitului și variația procesului, sub forma unor *metamodelle* de predicție fiabile. În continuare, această teză propune alte trei metode bazate pe extinderea metodologiei menționate mai sus în alte domenii de interes pentru industria semiconductorilor: analiza sensibilității cu variația procesului (globală și locală), verificarea modelului de simulare și predicția parametrică multivariabilă a randamentului.

1.5 Structura Tezei

Restul acestei teze este împărțit în 5 capitole. Capitolul 2 prezintă cercetări conexe, cu accent pe metodele de ultimă oră care implică utilizarea măsurilor de variație a procesului în verificarea funcțională. Capitolul 3 descrie fundamentele teoretice ale algoritmilor de regresie ML și ale altor metode legate de aceștia, toate utilizate în această teză. Capitolul 4 prezintă metodologia propusă pentru evaluarea precisă a impactului variației de proces asupra proiectării circuitelor, într-un stadiu incipient, metodologia Verification for Manufacturability by Modelling Process Variation - Circuit Performance Dependency (**P2P4M** - Process to Performance for Manufacturability), capabilă să ofere informații privind impactul variației de proces în scopul îmbunătățirii capacității de fabricație. Capitolul 5 se concentrează pe evidențierea unei serii de cazuri particulare de aplicare în care pot fi utilizate *metamodellele* de regresie precisă. În cele din urmă,

capitolul 6 prezintă concluziile finale, împreună cu rezumatul concis al contribuțiilor descrise în teză și perspectivele pentru cercetări viitoare.

Capitolul 2

Cercetări Conexe

2.1 Verificarea CI și Parametrii PCM

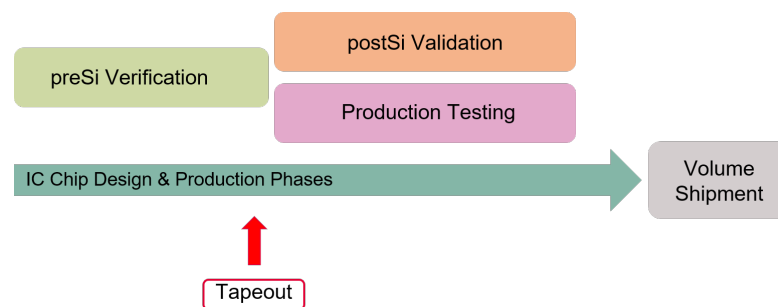


Figura 2.1 Etapele de verificare a proiectării și producției de CI

2.1.1 Verificarea Pre-Siliciu

Verificarea preSi implică testarea circuitului în timpul etapei de proiectare, pentru a asigura corectitudinea funcțională a acestuia înainte de fabricare. Aceasta implică evaluarea proiectului de CI într-un mediu virtual, în diferite scenarii, pe baza unor seturi de condiții de funcționare, utilizând simulări. Tehnicile sunt mai diverse și mai mature, dar de cele mai multe ori, acestea nu asigură o acoperire suficientă, făcând imposibilă eliminarea tuturor erorilor din etapa de proiectare [1] - practic, în ciuda tuturor eforturilor, colțurile procesului sunt predispuse să nu fie testate suficient.

2.1.2 Validarea Post-Siliciu

Scopul validării postSi este de a certifica comportamentul corect al cipului fabricat, având în vedere un set de condiții de funcționare predefinite [17]. Aceasta se operează pe primele cipuri fabricate (de obicei obținute pe plachete de testare) în medii reale.

2.1.3 Testarea DoE și Testarea în Producție

În timpul testării DoE, primele plachete fabricate (loturi DoE) sunt procesate și testate pentru a decide dacă proiectul nu va fi afectat de variațiile viitoare ale procesului [7]. Obiectivul principal al testării în producției este de a certifica faptul că CI împachetate funcționează în perfectă conformitate cu specificațiile din fișa tehnică.

2.1.4 Monitor de Control al Procesului (Process Control Monitor)

Pentru a menține variația procesului sub control, aceasta este supravegheată în mod constant în timpul procesului de fabricație, folosind tehnica monitorul de control al procesului (Process Control Monitor). Măsurătorile sunt efectuate pe structuri electrice înguste plasate pe plachetă printre matricele de producție, rezultatul fiind parametrii PCM, parametrii de dispozitiv (de obicei foarte numeroși) și acoperă domenii distincte: caracteristicile dispozitivului, atributele metalizării și monitorizarea defectelor electrice. Aceștia sunt utilizați pentru a caracteriza și controla tehnologia în raport cu specificațiile tehnologice [17]. Simularea schemelor PCM reprezintă o nouă paradigmă și este prezentată pentru prima dată în [26], pentru a ajuta la selectarea celor mai importante structuri de testare. În [19], PCM simulați și măsurați sunt utilizați pentru a rezolva ecuația de covarianță pentru modelarea statistică.

2.2 Analiza de Sensibilitate

2.2.1 Analiza de Sensibilitate Globală

SA globală analizează relația dintre incertitudinea în ieșirile sistemului și incertitudinea fiecărui factor de intrare, evaluată pe întreaga gamă a fiecărui factor de intrare [33]. Globabilitatea sa derivă din variația simultană a factorilor de intrare. Metodologiile de SA găsite în literatura de specialitate pot fi clasificate după cum urmează: metode bazate pe variabile (în care influența factorilor asupra ieșirii este cuantificată în mod direct, pe baza unor parametri de tip corelație) [24] și metode bazate pe modele (în care se obțin mai întâi dependențele funcționale dintre factorii de intrare și ieșire, iar modelul rezultat este utilizat ulterior pentru a cuantifica influența) [8].

2.2.2 Analiza de Sensibilitate Locală

SA locală evaluează impactul local al intrărilor asupra răspunsului sistemelor în proximitatea unui set de valori predefinite și poate fi utilă în mai multe domenii ale semiconductorilor, de exemplu în cazul DoE, dar unul dintre principalele sale dezavantaje este costul de calcul ridicat [5]. De obicei, SA locală este calculată folosind gradienti sau

derivate parțiale ale funcției de ieșire la valori specifice ale factorului de intrare, în timp ce valorile celorlalți factori de intrare sunt menținute constante [34].

2.3 Verificarea Modelului

Verificarea modelului face parte din verificarea formală și reprezintă tehnica primară pentru a inspecta comportamentul modelului de circuit în timp, stabilind dacă acesta îndeplinește o anumită specificație [22]. Verificarea statistică a modelului reprezintă o abordare bazată pe simulare utilizată pentru a verifica proprietățile statistice ale circuitelor complexe, în cazul în care verificarea tradițională a modelului nu este aplicabilă [14]. Verificarea modelului statistic poate deveni ineficientă și consumatoare de timp atunci când necesită simularea unui număr mare de evenimente rare (evenimente cu probabilitate scăzută). Aceasta poate fi accelerată prin generarea de evenimente rare frecvente. Verificarea modelului în funcție de variația procesului este următorul pas către o verificare eficientă a modelului, datorită importanței ridicate a determinării efectului variației procesului asupra specificației proiectului. Lucrarea din [32] abordează problema estimării unei regiuni sigure a spațiului parametrilor care asigură specificațiile de proiectare, pe baza parametrilor proveniți din variațiile de proces.

2.4 Predicția Randamentului

2.4.1 Concepte Generale

Randamentul reprezintă procentul de cipuri CI care îndeplinesc specificațiile. Numărătoarea Out-of-Spec (*OOS*) implică numărul real de cipuri care nu se încadrează în limitele specificațiilor. Atunci când această măsură de numărare este aplicată pe un număr mare de eșantioane (mii), poate oferi o estimare fiabilă cu o varianță redusă.

$$OOS = \frac{Nr. \text{ de cipuri out - of - specs}}{Nr. \text{ total de cipuri}} \quad (2.1)$$

Predicția parametrică a randamentului implică în principal prognoza prin generarea de eșantioane în etapa preSi, folosind simulări MC (pentru a fi relevante din punct de vedere statistic) și aplicarea ulterioară a metodelor de numărare a eșecurilor [9] (abordări de tip "simulare și numărare"), sau prin aplicarea metodelor statistice asupra datelor postSi (măsurate).

2.4.2 Abordări Avansate

Au fost evidențiate îmbunătățiri clare în ceea ce privește acuratețea și eficiența calculului atunci când se includ măsuri diversificate ale variației procesului. O nouă metodologie de estimare a randamentului care se bazează în întregime pe măsurători din siliciu este

prezentată de către [2]. În [31], autorii iau în considerare avantajul corelațiilor spațiale la nivel de placă între măsurătorile e-test (structuri de testare a liniilor de ștanțare) și măsurătorile de testare a sondei (performanțe ale circuitului), prin algoritmi de regresie pe bază de GP pentru a prezice măsurătorile (testare a sondei) pentru locațiile rămase ale matriței pe placă.

Capitolul 3

Fundamente Teoretice

3.1 Algoritmi de Regresie

3.1.1 Învățare Supervizată

Algoritmii de învățare supravegheată creează un model predictiv, adică o funcție, care mapează intrările către ieșire, pe baza datelor intrare-ieșire de antrenare etichetate [10], [15]. În consecință, se bazează pe disponibilitatea răspunsului vizat și urmărește minimizarea unei funcții de cost, prin aproximarea funcției deduse. Această funcție va fi utilizată în continuare pentru a prezice ieșirea sistemului, având în vedere noi intrări, care nu fac parte din datele de antrenare.

Fluxul unui algoritm de învățare supravegheată este descris în Fig. 3.1; pe lângă setul de date de antrenare, acesta implică un semnal de eroare utilizat pentru a rafina algoritmul în vederea determinării celui mai bun model de predicție.

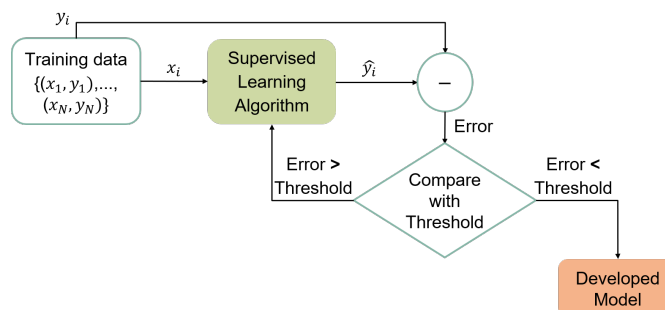


Figura 3.1 Fluxul de învățare supravegheată

3.1.2 Dezvoltări Recente ale Algoritmilor de Regresie

O problemă tipică de regresie, și anume adaptarea unui model care leagă o ieșire de un set de predictorii de intrare, poate fi abordată prin intermediul mai multor algoritmi de regresie: liniar, Ridge, Support Vector Machines, Proces Gaussian (Gaussian Process GP), Rețea Neuronală (Neural Network NN) cu mai multe straturi (MLP).

3.2 Îmbunătățirea Modelului prin Selecția Caracteristicilor

Selecția caracteristicilor, cunoscută și sub numele de selecție de variabile, reprezintă procedura de selectare a unui subset de caracteristici relevante (variabile de intrare) care explică răspunsul, eliminându-le pe celelalte din regresie. Un pas important în majoritatea problemelor de regresie este selectarea variabilelor [3], [16]. Astfel, se minimizează redundanța și se maximizează informația relevantă, pentru a obține cel mai bun regresor, corespunzător unui spațiu redus de variabile [30].

Pe baza strategiei de căutare, metodele de selectare a caracteristicilor pot fi clasificate în trei categorii: metode de filtrare, metode de împachetare și metode integrate.

3.3 Optimizarea Bayesiană (Bayesian Optimization)

Optimizarea sau ajustarea hiperparametrilor poate fi definită ca selectarea unui set de hiperparametri optimi pentru un anumit algoritm ML. În consecință, reprezintă o altă problemă importantă care trebuie abordată la antrenarea regresorilor, deoarece performanța acestora depinde în mare măsură de alegerea hiperparametrilor. Cele mai simple variante de căutare a hiperparametrilor optimi sunt Grid Search (GS) și căutarea aleatorie. O altă abordare este utilizarea optimizării automate a hiperparametrilor. O astfel de tehnică este Optimizarea Bayesiană (BO), una dintre cele mai puternice metode de identificare a extremelor funcțiilor obiectiv a căror evaluare este costisitoare [4], deoarece utilizează algoritmi de optimizare surogat pentru a cartografia iterativ dependența erorilor de hiperparametrii, dat fiind setul de date [4], [25].

BO utilizează două elemente în rezolvarea problemei de optimizare. În primul rând, o funcție surogat probabilistică, care cuprinde o distribuție anterioară capabilă să surprindă convingerile privind comportamentul funcției obiectiv (date de evaluare ale funcției) și un model de observație (distribuție posterioară), utilizat pentru a descrie modul de generare a datelor. În al doilea rând, o funcție de achiziție utilizată pentru a ghida căutarea, prin indicarea următorului punct interogant, planificat pe baza distribuției posterioare. Una dintre principalele caracteristici ale BO este faptul că nu se bazează pe aproximări locale ale gradientului și ale Hessianului (fără derivate), ci utilizează întreaga informație disponibilă din evaluările anterioare ale funcției [25]. În consecință, poate

găsi minimumul chiar și în cazul funcțiilor neconvexe dificile, cu un cost de calcul mai mică (relativ puține iterații), numai că petrece mai mult timp pentru a determina următorul punct de eșantionare. Prin urmare, poate face față cu ușurință incertitudinilor legate de funcțiile stocastice de tip black-box, deși poate deveni destul de lent în cazul problemelor cu un număr mare de hiperparametri.

Capitolul 4

Metodologia Verification for Manufacturability by Modelling Process Variation - Circuit Performance Dependency (P2P4M)

Acest capitol prezintă metodologia propusă pentru evaluarea impactului variației procesului asupra proiectării circuitelor. Metodologia propusă, Verification for Manufacturability by Modelling Process Variation - Circuit Performance Dependency (**P2P4M**), se bazează pe modelarea dependențelor funcționale și statistice dintre performanțele circuitului (EP) și variația procesului de fabricație (PCM), într-o fază incipientă, prin utilizarea algoritmilor ML pe datele preSi.

4.1 Fluxul Metodologiei

4.1.1 Cadrul General

O reprezentare schematică a unei metodologii unificate de selecție a caracteristicilor și de BO a hiperparametrilor pentru antrenarea modelelor de regresie este prezentată în Fig. 4.1.

4.1.2 Formularea Problemei și Fluxul Metodologiei P2P4M

Scopul metodologiei **P2P4M** este de a exprima o relație optimă sub forma ecuației 4.1 prin intermediul unui model ML, utilizând doar simularea MC preSi și fără cunoștințe

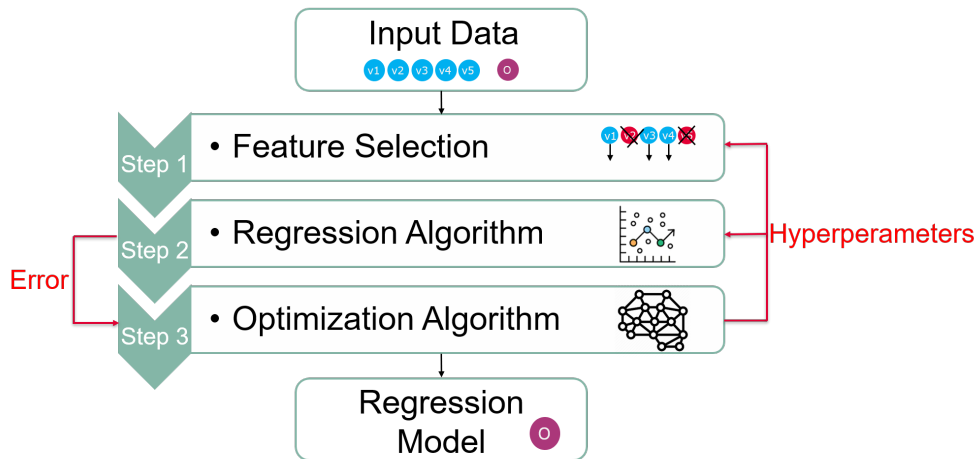


Figura 4.1 Reprezentarea schematică a cadrului generalizat pentru antrenarea regresiei bazată pe optimizare

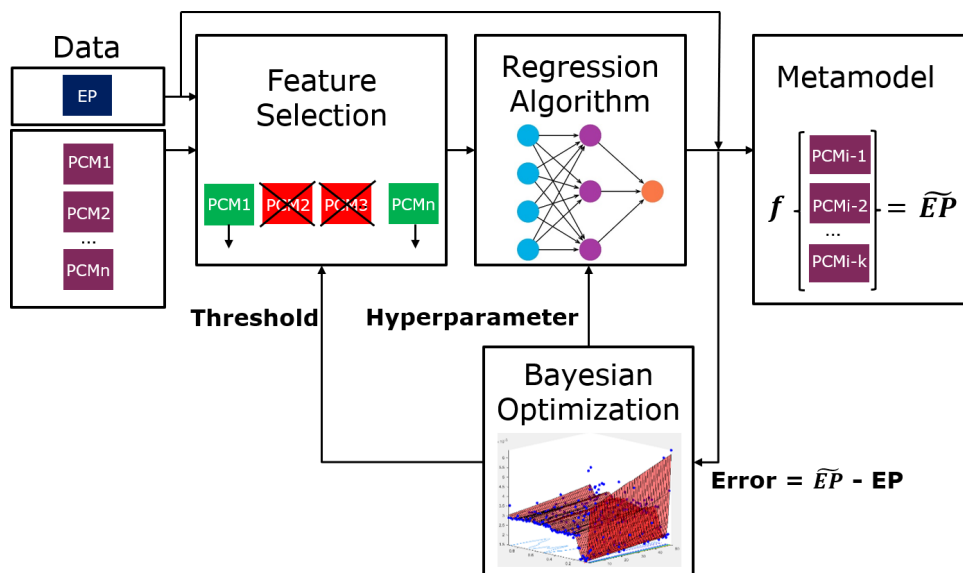


Figura 4.2 Reprezentare schematică a metodologiei **P2P4M** [42]

preliminare suplimentare cu privire la posibilele dependențe dintre variabilele luate în considerare, și anume fiecare dintre EP și PCM, așa cum arată Fig. 4.2.

$$EP = f(PCM_i) + \varepsilon \quad (4.1)$$

4.2 Blocul de Selecție a Caracteristicilor

Pentru metodologia **P2P4M** propusă, am utilizat o metodă de selecție a caracteristicilor bazată pe metrici de corelație,utilizând două dintre cele mai recente progrese în domeniu,

considerate a fi printre cele mai bune metrice pentru cuantificarea dependenței dintre oricare două variabile aleatoare (EP și PCM în cazul nostru):

- (Brownian) Distance Correlation - *DistCorr*: măsoară gradul de independență dintre două variabile [29] și se bazează pe mișcarea browniană.
- Maximal Information Coefficient - *MIC*: o metrică bazată pe informații reciproce care măsoară gradul de corelație dintre cele două variabile considerate [20].

4.3 Antrenarea Modelului bazat pe Date preSi

Al doilea pas al metodologiei **P2P4M** constă în antrenarea unui model de regresie MLP NN cu 3 straturi de tip feedforward (algoritmul de backpropagare Levenberg-Marquardt și funcția de activare tangentă hiperbolică sigmoidă *tansig*) - un *metamodel* pentru EP studiat, la fiecare pas de iterație determinat de BO, pe baza subsetului de PCM influenți determinat de blocul de selecție a caracteristicilor și a numărului de neuroni din stratul ascuns selectat în mod optim de BO. Antrenarea utilizează subsetul de antrenare a datelor disponibile, perechi de PCM predeterminați și valori corespunzătoare ale fiecăruia dintre EP studiate. În continuare, valorile estimate (\widetilde{EP}) sunt comparate cu cele țintă (EP_{train}) și se ajustează parametrii NN.

4.4 Optimizarea Bayesiană (Bayesian Optimization) a Modelului Antrenat

Metodologia **P2P4M** utilizează BO pentru a dezvolta iterativ un model statistic global pentru funcția obiectiv formată din 2 variabile - pragul metricii de selecție a caracteristicilor și numărul de neuroni din stratul ascuns al NN. Spațiul de intrare este un spațiu bidimensional, iar la fiecare iterație se urmărește găsirea perechii de intrare promițătoare (*FSthreshold* și *neuronsNumber*), antrenarea unui nou *metamodel* cu ajutorul acesteia, urmată de evaluarea funcției care constă în minimizarea erorii reziduale a *metamodelului* calculată pe setul de testare ($Error = \widetilde{EP} - EP$). Implementarea BO utilizează GP (baza pe nucleul Matérn 5/2) ca funcție surogat și funcția de achiziție *expected-improvement-plus*.

4.5 Rezumatul Metodologiei P2P4M

Algoritmul rezultat pentru metodologia **P2P4M** este sintetizat în tabelul 4.1.

Tabel 4.1 Algoritmul metodologiei **P2P4M**

Parametrii necesari: EP , PCM , $maxNN$, $itNumber$
1: Divizarea setului de date antrenare-testare (EP_{train} , EP_{test} , PCM_{train} , PCM_{test})
2: $FSmetrics = DistCorr(EP_{train}, PCM_{train})$ (v1) $FSmetrics = MIC(EP_{train}, PCM_{train})$ (v2)
3: $neuronsNumber \leftarrow optimizableVariable([2, maxNN])$
4: $FSthreshold \leftarrow optimizableVariable([\min(FSmetrics), \max(FSmetrics)])$
5: OptResults = $BayesianOptimization(EP_{train}, EP_{test}, PCM_{train}, PCM_{test}, FSmetrics, neuronsNumber, itNumber)$
6: $PCM_i = PCM(FSmetrics \geq \mathbf{OptResults.FSthreshold})$
7: $metamodel = NNtrain((EP_{train}, PCM_{i-train}, \mathbf{OptResults.neuronsNumber})$

4.6 Modelarea Distribuției postSi și Validarea Metodologiei

Fig. 4.3 ilustrează cadrul de predicție a distribuțiilor EP postSi pe baza *metamodelor* **P2P4M**. Acesta necesită distribuția care reflectă fereastra actuală a procesului ($P(PCM_r)$), *metamodelul* individual al fiecărui EP obținut anterior, sub forma unei ecuații matematice care leagă fiecare dintre EP studiați și subsetul de PCM influenți ($f(PCM_{r-i})$), precum și eroarea de predicție ($P(\epsilon)$). Distribuția performanțelor circuitului ($P(\widehat{EP}_r)$) este calculată ca suprapunere între valorile EP prezise de *metamodel* și eroarea de antrenare diferită de zero, care cuantifică impactul altor factori asupra PE, neincluși în analiza inițială.

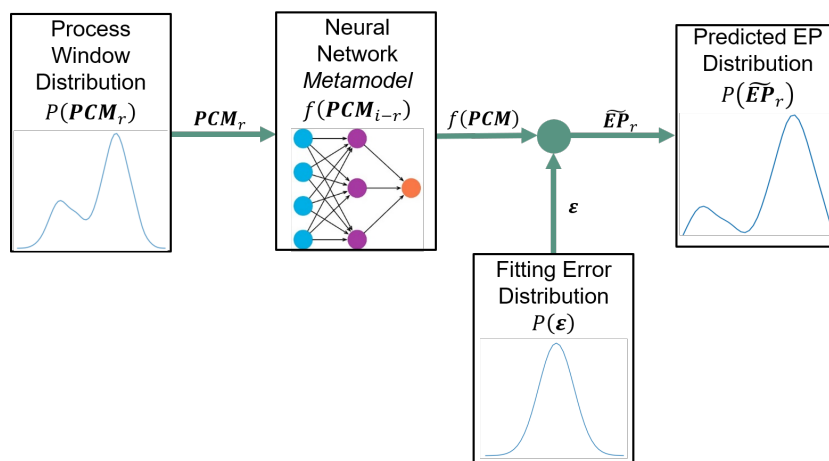


Figura 4.3 Cadrul de predicție a distribuției EP postSi

4.7 Aplicarea Metodologiei P2P4M

4.7.1 Unificarea Selecției Caracteristicilor și Optimizarea Bayesiană a Hiperparametrilor

Tabelul 4.2 rezumă rezultatele obținute pe un set de date reale format din $n = 93$ variabile de intrare și o variabilă de ieșire, împărțite în $n_{train} = 862$ și $n_{test} = 100$ eșantioane. RMSE calculat pe setul de date de testare are același ordin de mărime pentru toate cele patru implementări. Cu toate acestea, cel mai mic RMSE a fost obținut atunci când s-a aplicat selecția caracteristicilor asupra variabilelor de intrare. Principalele avantaje ale metodologiei **P2P4M** sunt viteza și costul de calcul; același RMSE a fost obținut cu numai 7% din iterații.

Tabel 4.2 RMSE, numărul de neuroni și pragul *DistCorr* obținut pe setul real de date

Setări de Antrenare & Testare	minRMSE	Numărul de Neuroni	Pragul <i>DistCorr</i>
GS pe numărul de neuroni	0.0481	3	-
BO pe numărul de neuroni	0.0525	7	-
BO pe numărul de neuroni & GS pe pragul <i>DistCorr</i>	0.0396	2	0.1
BO pe numărul de neuroni & pe pragul <i>DistCorr</i> (P2P4M)	0.0398	2	0.1444

4.7.2 Modelarea Dependentei Funcționale și Identificarea PCM Influenți

Tabelul 4.3 prezintă rezultatele metodologiei **P2P4M** și indicatorii de acuratețe pe un set de date de 92 PCM și 5 EP. Selecția caracteristicilor crește precizia predicției (*MSPE*) de 2 până la 8 ori. *Metamodelele* sunt fiabile, având în vedere corelația dintre valorile prezise și valorile țintă ($\rho_{\widetilde{EP}-EP}$, precum și lipsa de corelație între eroarea de antrenare și valorile prezise ($\rho_{\varepsilon-\widetilde{EP}}$).

4.7.3 Modelarea și Validarea Distribuțiilor preSi și postSi

Tabelul 4.4 rezumă rezultatele a două metrici de similitudine - distanța Bhattacharyya și distanța Wasserstein, menite să cuantifice distanța statistică dintre distribuția EP reală și distribuția EP modelată **P2P4M**. Valoarea pentru preSi - postSi ($EP_{preSi} - EP_{postSi}$) este considerată punct de referință. După cum era de așteptat, similitudinea dintre distribuția simulată și cea estimată pe baza ei este ridicată pentru toți parametrii. Se poate observa, de asemenea, un grad ridicat de similitudine între distribuția modelată postSi; în plus, există o apropiere de un ordin de mărime între distribuția estimată postSi și distribuția

Tabel 4.3 Metricele de antrenare și rezultatele metodologiei **P2P4M** pentru: (1) Fără selecție de caracteristici, (2) Selecția caracteristicilor cu metrica *DistCorr*, (3) Selecția caracteristicilor cu metrica *MIC*.

Parametru		EP ₁	EP ₂	EP ₃	EP ₄	EP ₅
Fără Selecție de Caracteristici	<i>MSPE</i>	0.088	0.181	0.187	0.145	0.166
	$\rho_{\widetilde{EP}-EP}$	0.385	0.289	0.273	0.214	0.232
	$\rho_{\varepsilon-\widetilde{EP}}$	0.529	-0.649	-0.615	-0.529	-0.426
<i>DistCorr</i>	<i>MSPE</i>	0.041	0.083	0.086	0.024	0.024
	$\rho_{\widetilde{EP}-EP}$	0.820	0.607	0.619	0.900	0.851
	$\rho_{\varepsilon-\widetilde{EP}}$	-0.026	0.022	-0.030	-0.010	0.065
<i>MIC</i>	<i>MSPE</i>	0.041	0.083	0.087	0.022	0.024
	$\rho_{\widetilde{EP}-EP}$	0.823	0.592	0.592	0.899	0.841
	$\rho_{\varepsilon-\widetilde{EP}}$	-0.077	-0.079	0.019	-0.113	0.065

Tabel 4.4 Metrice de similitudine între distribuțiile EP reale și modelate, bazate pe simulări MC preSi sau măsurătorilor postSi reale

Parametru	Metrică de similitudine	EP ₁	EP ₂	EP ₃	EP ₄	EP ₅
$EP_{preSi} - \widetilde{EP}_{preSi}$	Distanța Bhattacharyya	0.0025	0.030	0.0040	0.0011	0.0015
	Distanța Wasserstein	0.0123	0.0139	0.0158	0.0081	0.0097
$EP_{postSi} - \widetilde{EP}_{postSi}$	Distanța Bhattacharyya	0.0017	0.0026	0.0032	0.0033	0.0029
	Distanța Wasserstein	0.0120	0.0144	0.0146	0.0155	0.0145
$EP_{preSi} - EP_{postSi}$	Distanța Bhattacharyya	0.0491	0.0317	0.0265	0.0342	0.6187
	Distanța Wasserstein	0.2208	0.1496	0.1451	0.1787	0.4583

măsurată postSi (rândul al treilea), în comparație cu valoarea de referință. Diagramele marginale *cdf* ale EP reprezentate în fig. 4.4 ilustrează acest lucru. Distribuția postSi modelată cu ajutorul abordării propuse, bazată pe eşantioane PCM postSi măsurate (linia roșie) se aseamănă în întregime cu distribuția postSi reală (linia verde). Chiar și atunci când există o diferență semnificativă între distribuția preSi și postSi, așa cum este cazul EP₄ (Fig. 4.4(d)), metodologia **P2P4M** este capabilă să se adapteze la schimbările tehnologice, iar distribuția modelată este mult mai apropiată de cea reală (linia verde).

4.7.4 Fiabilitatea Metodologiei

Ca o etapă finală, fiabilitatea și coerența metodologiei au fost evaluate pe parcursul a patru rulări, pentru a evalua capacitatea de funcționare printru două seturi de date PCM: *initialSet93* - 93 PCM care sunt simulați în timpul preSi și măsurători în faza postSi

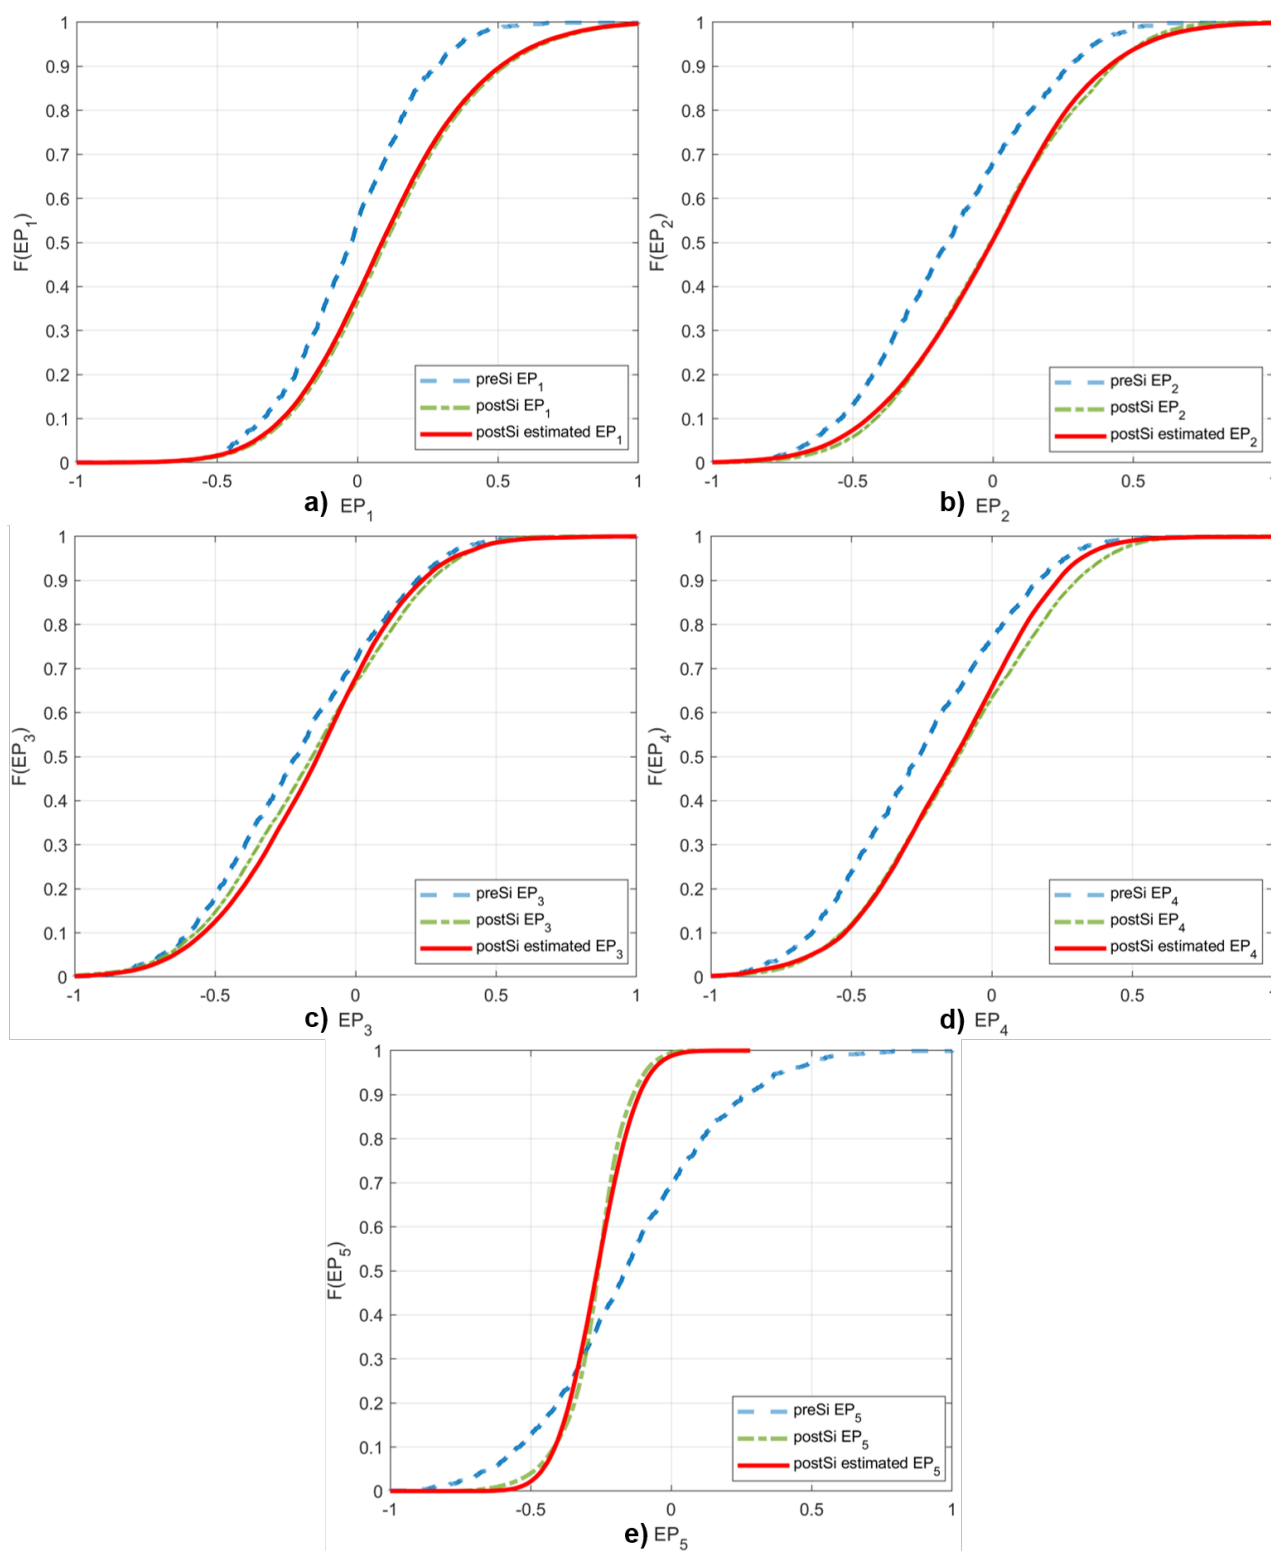


Figura 4.4 Graficele *cdf* pentru distribuțiile EP studiate în: (1) simulare (preSi), (2) producție (postSi), (3) predicție *metamodel* bazată pe eșantioane postSi (postSi estimat)




Figura 4.5 Rezultatele fiabilității și consistenței **P2P4M** obținute în timpul celor 4 rulări pentru EP₁₁

și *extendedSet198* - 198 PCM, *initialSet93* plus 105 PCM suplimentari care nu sunt monitorizați în postSi. Influența mare a setului de date extins asupra performanței metodologiei **P2P4M** este subliniată în fig. 4.5. În mod clar, rezultatele *initialSet93* pe EP₁₁ reprezintă un exemplu explicit al comportamentului unui EP care este explicat deficitar de setul de parametri PCM disponibil. Chiar și cu un prag *DistCorr* cuprins între 0.19 și 0.31, *MSPE* al *metamodelelor* este în jurul valorii de 0.12. În plus, acuratețea scăzută este susținută de o corelație mai mică de 0.35 între valorile estimate și valorile țintă ale EP. Metodologia a selectat doi PCM influenți - PCM₂ și PCM₃₀, care prezintă valori importante de corelație de 0.3468 și, respectiv, 0.32549. Cu toate acestea, luând în considerare toate rezultatele, se poate concluziona că setul inițial de parametri PCM disponibil nu este potrivit pentru a descrie în mod corect EP₁₁. PCM cu indicii de la 189 la 193 prezintă cea mai mare corelație cu EP₁₁ și ar trebui cu siguranță să fie monitorizați în timpul fazei de producție postSi de către tehnologi.

Folosirea *extendedSet198* contribuie la îmbunătățiri semnificative ale acurateței *metamodelelor*. Media *MSPE* a scăzut la 0.02, în timp ce corelația Pearson între țintă și predicție a ajuns la 0.97. *Metamodelele* precise și optime sunt antrenate pe baza unui set PCM format din 14 parametri, după cum arată ultimul grafic din 4.5. În mod similar, fig. 4.6 prezintă coeficienții de corelație dintre setul extins de PCM și EP₁₁. Există o relație directă între valorile *metamodelele* îmbunătățite și valorile metricii *DistCorr* afișate de cei 105 PCM suplimentari - corelația maximă a distanței atinge 0.6983, aproape dublu față de valoarea metrică maximă a corelației dintre EP₁₁ și PCM-ul *initialSet93*.

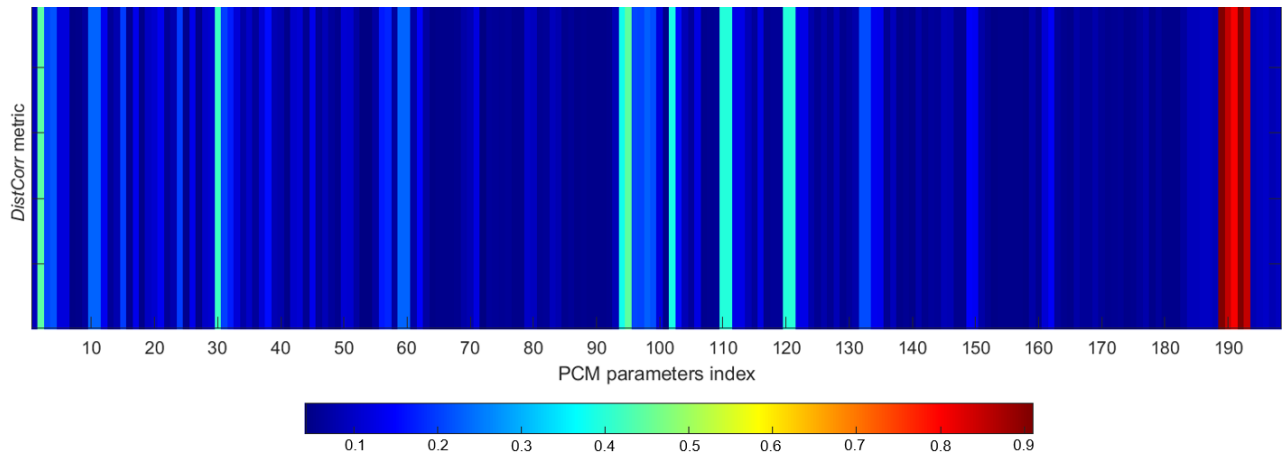


Figura 4.6 Coeficienții de corelație *DistCorr* dintre PCM din *extendedSet198* și EP_{11}

Capitolul 5

Cazuri Particulare de Aplicare ale Metodologiei P2P4M

Acest capitol prezintă activitatea dezvoltată în contextul mai multor cazuri de utilizare a metodologiei **P2P4M**, menite să ofere instrumente eficiente în abordarea unor probleme cunoscute din domeniul semiconductorilor. Motivația a fost dată de oportunitatea de a beneficia pe deplin de atuurile *metamodelului*, precum și de a introduce noi metodologii adaptate pentru provocările clasice ale CI, în contextul variației procesului.

5.1 Cazul 1: Analiza de Sensibilitate cu Variația Procesului

5.1.1 Metodologia de Analiză de Sensibilitate Globală

Fig. 5.1 descrie în detaliu etapele metodologiei de SA globală propusă. Prima etapă presupune aplicarea cadrului **P2P4M** pentru EP vizat și obținerea *metamodelului* optim. În continuare, relația capturată este evaluată pentru a extrage setul de PCM rezultat care reprezintă factorii influenți (PCM_i), așa cum este determinat în mod optim de BO, pe baza erorii reziduale a setului de testare a modelului NN. În ultima etapă se calculează indicii de sensibilitate S_j , pe baza metricii *DistCorr* sau *MIC*, așa cum este descris în ec. 5.1, iar PCM sunt clasificați. Un S_j mai mare înseamnă un impact mai mare.

$$\begin{aligned} S_j &= DistCorr(EP, PCM_{i-j}) \\ S_j &= MIC(EP, PCM_{i-j}) \end{aligned} \quad (5.1)$$

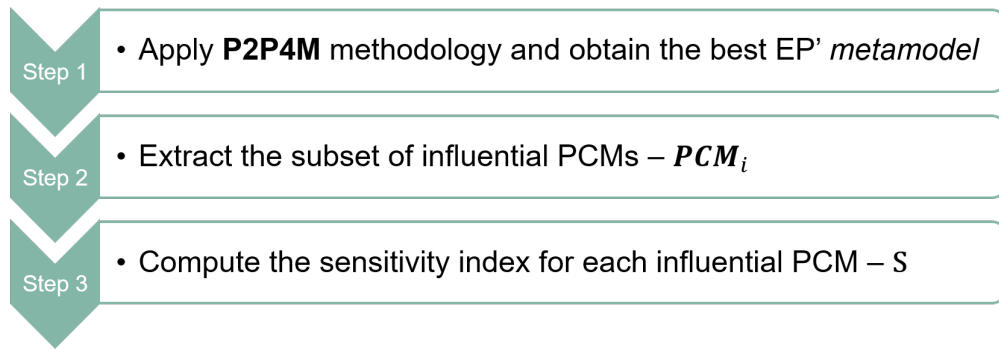


Figura 5.1 Etapele metodologiei de analiză a sensibilității globale

5.1.2 Metodologia de Analiză de Sensibilitate Locală

Etapele metodologiei propuse pentru SA locală sunt detaliate în fig. 5.2. Primul pas este același ca și în cazul metodologiei globale de SA - cadrul **P2P4M** trebuie aplicat pentru fiecare EP vizat pentru a obține cel mai bun *metamodel*. Relația încapsulată de fiecare *metamodel* este formulată ca în ec. 5.2, unde tangenta hiperbolică (*tanh*) reprezintă funcția de activare NN, IW^T este vectorul de ponderi din stratul de intrare în stratul ascuns, LW^T este vectorul de ponderi din stratul ascuns în stratul de ieșire și B reprezintă vectorul de polarizare din stratul de intrare în stratul ascuns.

$$\widehat{EP} = LW^T \tanh(IW^T PCM_i + B) \quad (5.2)$$

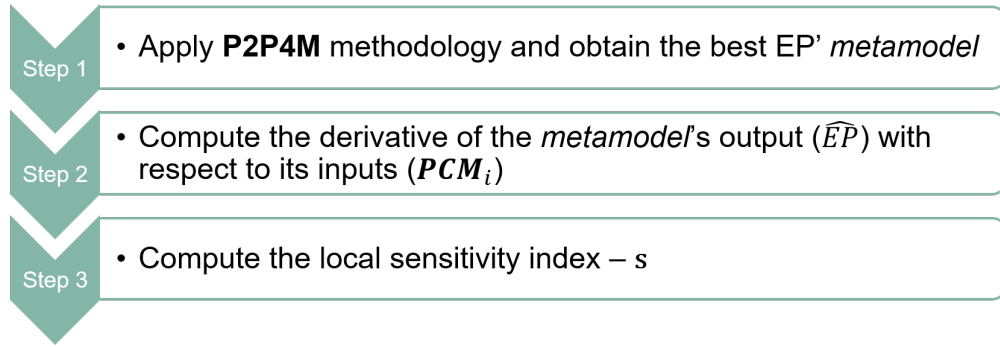


Figura 5.2 Etapele metodologiei de analiză a sensibilității locale

A doua etapă constă în calcularea derivatei fiecărui \widehat{EP} (ieșirea *metamodelului*) în raport cu PCM săi influenți - PCM_i (intrările *metamodelului*), pentru a obține derivatele parțiale. În cele din urmă, se calculează indicii de sensibilitate locală, sub forma ec. 5.3, unde PCM_0 este punctul utilizat pentru a calcula SA locală a EP în raport cu al j^{th} PCM influent - PCM_{i-j} .

$$s_{j|PCM_0} = \frac{\partial \widehat{EP}}{\partial PCM_{i-j}}(PCM_0) \quad (5.3)$$

Sensibilitatea locală a performanței unui circuit cu n PCM influenți este definită ca fiind norma euclidiană a tuturor indicilor de sensibilitate locală:

$$S_{|PCM_0} = \|[s_{1|PCM_0}, s_{2|PCM_0}, \dots, s_{n|PCM_0}]\|_2 \quad (5.4)$$

5.1.3 Rezultate Experimentale

Analiza de Sensibilitate Globală

În tabelul 5.1 este listat setul clasificat de PCM influenți pentru fiecare dintre EP pentru setul de date considerat (92 PCM) și indicele de sensibilitate corespunzător, pentru ambele metrici - *DistCorr* și *MIC*. Atunci când se corelează aceste date cu rezultatele din tabelul 4.3, se poate observa cu ușurință că magnitudinea generală a acestor metrici pentru fiecare dintre EP este puternic corelată cu precizia modelelor de regresie. Diagramele de dispersie dintre EP_3 și PCM_{29} și PCM_{92} prezintă o simetrie vizuală a axei care dovedește independența statistică dintre EP și PCM. Pe de altă parte, diagrama de dispersie dintre EP_4 și PCM_{42} , așa cum este descrisă în fig. 5.3, evidențiază prezența unei dependențe statistice între cei doi parametri. Coordonând acest rezultat cu corelația ușor mai mare dintre valorile estimate și cele țintă ale EP_4 ($\rho_{\widehat{EP}_4-EP_4}$ - tabelul 4.3), se întărește influența pe care PCM_{42} o exercită asupra EP considerat. În final, ultimele rezultate demonstrează că implementarea *DistCorr* poate fi validată ca fiind mai potrivită ca metodă de selecție a caracteristicilor decât *MIC* pentru acest caz particular.

Tabel 5.1 Indicii de analiză a sensibilității *DistCorr* și *MIC* și clasamentul PCM influenți

Parametru	<i>DistCorr</i>		<i>MIC</i>	
	PCM Influenți	$S_{DistCorr}$	PCM Influenți	S_{MIC}
EP ₁	PCM ₂	0.4567	PCM ₂	0.2885
	PCM ₂₇	0.4532	PCM ₂₇	0.2710
	PCM ₄	0.4068	PCM ₄	0.2504
	PCM ₂₉	0.2816	PCM ₂₉	0.2075
EP ₂	PCM ₂₇	0.2252	PCM ₄	0.1721
	PCM ₂	0.2235	PCM ₂	0.1697
	PCM ₄	0.2183	PCM ₂₇	0.1686
EP ₃	PCM ₄	0.1901	PCM ₂	0.1977
	PCM ₂₇	0.1573	PCM ₂₇	0.1888
	PCM ₂	0.1401	PCM ₉₂	0.1657
			PCM ₄	0.1646
			PCM ₂₉	0.1619
EP ₄	PCM ₄₃	0.8031	PCM ₄₃	0.6528
	PCM ₄₂	0.2060		
EP ₅	PCM ₄₂	0.8096	PCM ₄₂	0.6074
	PCM ₄₃	0.3798	PCM ₄₃	0.2202




Figura 5.3 Diagrama de dispersie între EP₄ și PCM influent suplimentar selectat prin metrica *DistCorr* (PCM₄₂)

Analiza de Sensibilitate Locală

Fig. 5.4 rezumă performanțele metodologiei atunci când se execută cele 2 experimente propuse - calcularea sensibilităților locale totale în toate colțurile și a punctului de sensibilitate maximă în cadrul PCM influenți folosind un optimizator local. Nu există

puncte de sensibilitate maximă care să depășească valoarea maximă a sensibilității locale calculate în colțurile PCM influenți pentru niciunul dintre EP. Cu toate acestea, punctele critice nou obținute, indicate în limitele specificațiilor PCM influenți, introduc în continuare o sensibilitate ridicată. De exemplu, pentru EP₂, sensibilitatea locală totală în punctul de sensibilitate maximă (1.2849) este comparabilă cu sensibilitatea locală totală din cel mai dezavantajos colț (obținut pentru PCM₂ la LSL, PCM₄ la LSL, PCM₂₇ la USL).

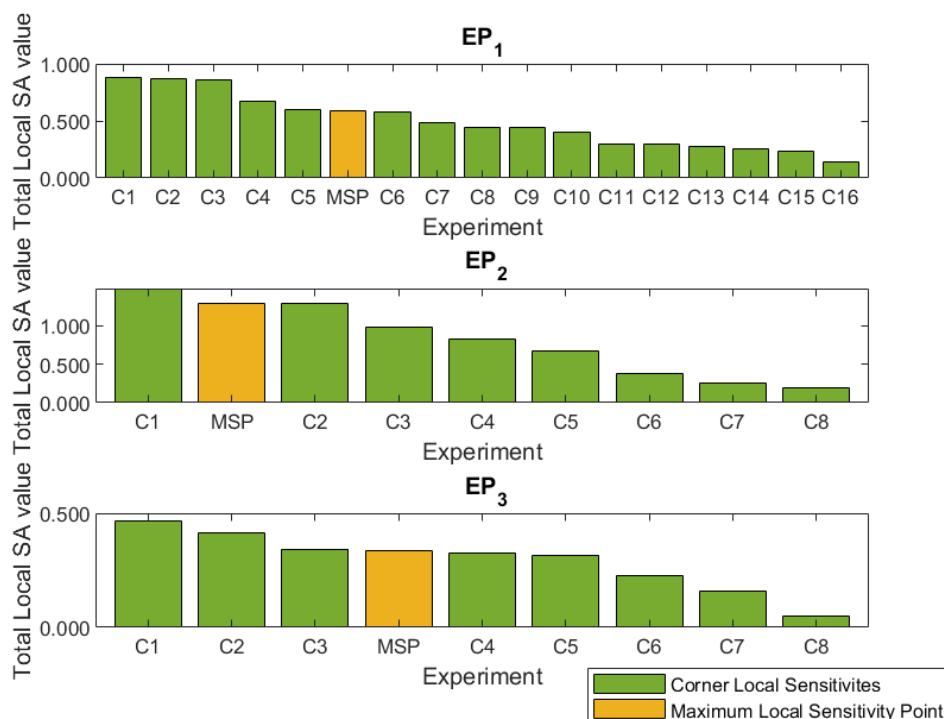


Figura 5.4 Ierarhizarea valorilor SA locale totale calculate pentru EP studiat

5.2 Cazul 2: Verificarea Modelului de Simulare

5.2.1 Fluxul Metodologiei

Fig. 5.5 evidențiază etapele metodologiei de verificare a modelului de simulare variația de proces și se bazează pe existența discrepanțelor sau disparităților în distribuții. Metodologia ar trebui să fie utilizată pentru un singur EP la un moment dat, pentru care metodologia **P2P4M** a fost deja aplicată, obținându-se astfel *metamodelul* optim, precum și metodologia globală SA introdusă și clasamentul rezultat al PCM influenți. Pe lângă aceasta, metodologia necesită distribuții preSi și postSi pentru EP studiat și pentru întregul set de PCM influenți - PCM_i .

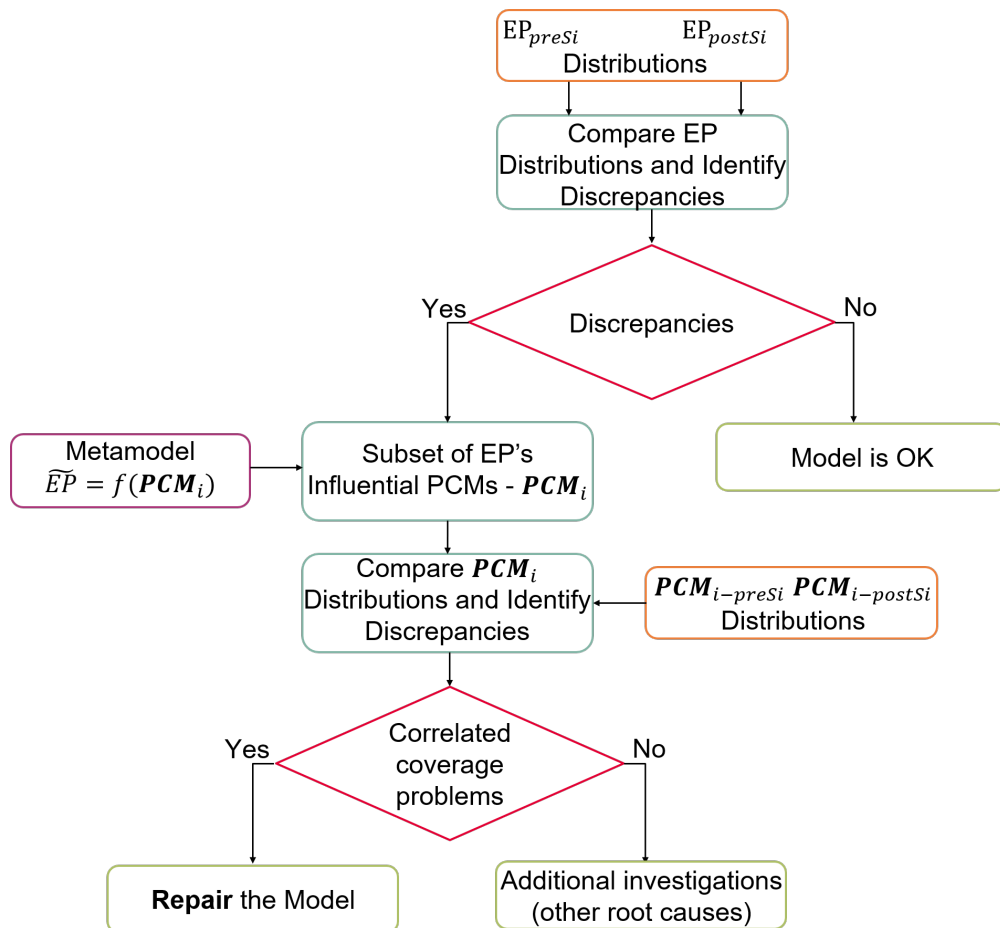


Figura 5.5 Etapele metodologiei de verificare a modelului

5.2.2 Rezultate Experimentale

Fig. 5.6 prezintă un EP critic, și anume EP₆, care prezintă atât discrepanțele dintre distribuții, cât și depășirea specificațiilor în ceea ce privește distribuția postSi. Se poate observa cu ușurință că distribuțiile de pe plachetele 47 și 48 prezintă distorsiuni clare în comparație cu restul plachetelor și o deplasare spre dreapta. În plus, distribuțiile plachetelor 4, 39, 40, 43 și 46 au media deplasată spre dreapta în comparație cu distribuția preSi, care, în teorie, ar trebui să acopere toate variațiile postSi. EP₆ prezintă opt PCM influenți găsiți prin metodologia **P2P4M**; cel mai influent - PCM₉₁ nu prezintă disparități ale distribuțiilor. Cu toate acestea, PCM₅, clasat pe locul al doilea ($S_{DistCorr}$ de 0.2815), prezintă în fig. 5.7 deplasarea spre dreapta a distribuțiilor postSi și a celor istorice, ambele încălcând limita superioară de specificație, în afară de distribuția preSi care nu reușește să acopere variația procesului.

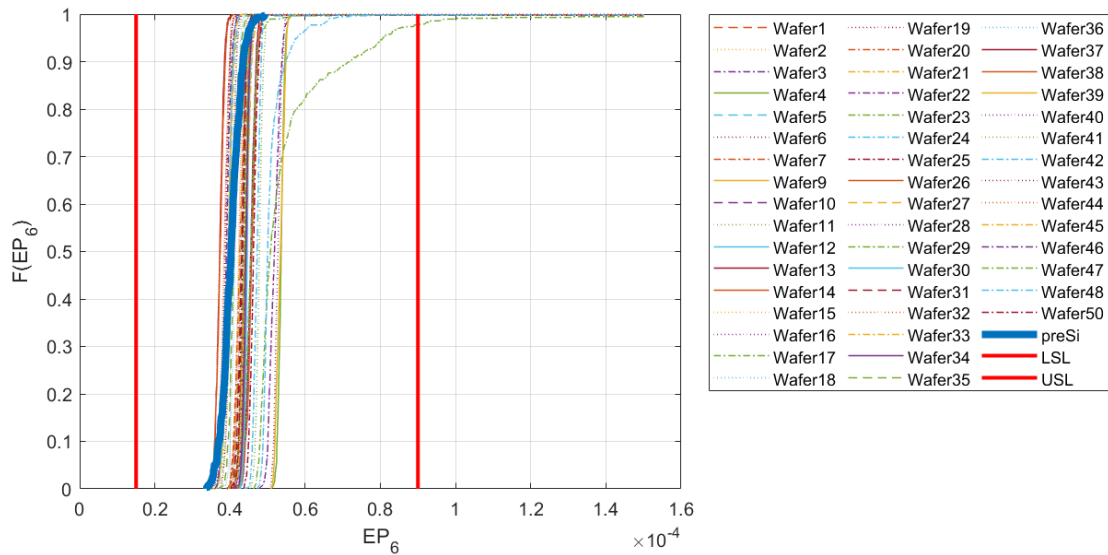


Figura 5.6 Graficul *cdf* pentru distribuțiile preSi și postSi ale EP_6




Figura 5.7 Diagrama *cdf* pentru distribuțiile preSi, postSi și istorice ale PCM_5

5.3 Cazul 3: Predicția Randamentului

5.3.1 Metodologia de Predicție a Randamentului PreSi pentru Distribuțiile Normale

Prima metodologie are ca scop prezicerea randamentului parametric într-un stadiu incipient, pe baza *metamodelor* metodologiei **P2P4M**, pentru EP și PCM care prezintă distribuții normale. Fig. 5.8 descrie etapele abordării propuse pentru un EP care, în loc să simuleze răspunsurile circuitului cu ajutorul MC, utilizează dependența dintre EP și

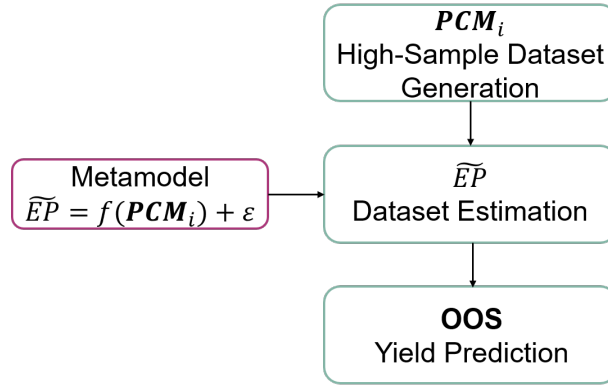


Figura 5.8 Fluxul metodologiei de predicție a randamentului preSi pentru distribuțiile normale

setul de date al PCM influenți. Mai precis, începe cu generarea artificială a unui set de date cu un număr mare de eșantioane (milioane de eșantioane) pentru PCM influenți (PCM_i), prin modelarea distribuțiilor PCM ca o distribuție normală multivariată, urmată de estimarea eșantioanelor corespunzătoare ale EP (\widetilde{EP}), pe baza relației încapsulate de *metamodelul* corespunzător. În cele din urmă, predicția randamentului este calculată cu ajutorul metricii *OOS*, prin numărarea eșantioanelor EP care se situează în afara limitelor de specificație.

5.3.2 Metodologia de Predicție a Randamentului Parametric

Algoritmul este prezentat în tabelul 5.2 și are nevoie de *metamodelul* fiecărui EP, împreună cu distribuțiile PCM influenți (PCM_i) și distribuția erorilor de antrenare a *metamodelului* pentru parametrul de performanță analizat. Pentru a calcula metrica *OOS*, sunt necesare, de asemenea, limitele de specificație ale parametrilor *LSL* și *USL*. Punctul cheie al acestei noi abordări este capacitatea sa de a face față distribuțiilor non-normale, care sunt prezente atât pentru PCM, cât și pentru eroarea de antrenare, pe baza utilizării metodei *distFit* prezentată în [11], un cadru de ajustare a distribuțiilor multivariate capabil să genereze date în conformitate cu distribuția modelată. Apoi, valorile EP corespunzătoare sunt estimate pe baza *metamodelului*, a valorilor PCM generate sintetic (PCM_{i-gen} și a erorii de estimare modelate (ε_{gen}), rezultând astfel \widetilde{EP} . În cele din urmă, se calculează *OOS* pentru EP studiat pe baza ec. 5.5.

$$OOS_{EP} = \frac{\text{nr. de eșantioane în afara specițiilor}}{\text{nr. total de esantioane}} \quad (5.5)$$

Tabel 5.2 Algoritm de predicție parametrică a randamentului

Required parameters: $\widetilde{EP} = f(PCM_i) + \varepsilon$, PCM_i , ε , $LSLEP$, $USLEP$
1: Generarea $\varepsilon_{gen} \sim distFit(\varepsilon)$
2: Generarea $PCM_{i-gen} \sim distFit(PCM_i)$
3: $\widetilde{EP} = f(PCM_{i-gen} + \varepsilon_{gen})$
4: Contorizarea $OOS_{\widetilde{EP}}$

5.3.3 Rezultate Experimentale

Predicția Randamentului PreSi pentru Distribuțiile Normale

Tabelul 5.3 prezintă rezultatele obținute pentru 3 EP și pentru întregul produs (considerând setul de date pe care s-a aplicat metodologia propusă). Soluția propusă obține valori *OOS* similare, dar mai mici decât referința considerată (valorile *OOS* calculate pe setul de date inițial preSi). Pe de altă parte, trebuie avută în vedere variația ridicată a *OOS* atunci când este calculată pe seturi de date mici, ceea ce este exact cazul datelor preSi utilizate. În consecință, performanța metodologiei propuse este mai bună decât abordarea care constă în calcularea simplă a *OOS* pe un set de date mic de simulări MC, obținându-se o varianță mai mică în predicție.

Tabel 5.3 Rezultatele predicției pierderilor de randament atât pentru cele trei EP studiate, cât și pentru întregul produs - rezultatele de referință preSi și rezultatele metodologiei propuse

Metoda		EP ₁	EP ₂	EP ₃	Produs
<i>OOS</i> EP _{preSi} (%) (962 eşantioane)		0.84	0.60	0.73	0.94
<i>OOS</i> \widetilde{EP} (1,200,000 eşantioane)	μ (%)	0.92	0.75	0.85	1.04
	σ (%)	0.15	0.13	0.14	0.17

Predicția Randamentului Parametric

Fig. 5.9 prezintă reprezentarea vizuală a rezultatelor obținute pentru EP₃ (a) și pentru cazul multivariat (produs) (b), concentrându-se pe distribuțiile obținute în 10 iterații a fiecărei metode și pe valorile de referință (*OOS*s pe eşantioane preSi și postSi). *Metoda* 2 (algoritm prezentat în tabelul 5.3) depășește *Metoda* 1, deoarece prezintă varianță mai mică. *Metoda* 1 a presupus calcularea metricii *OOS* pentru fiecare dintre EP pe un set de date obținut după cum urmează: în primul rând, au fost estimaet 220 de eşantioane pentru EP , utilizând *metamodele* **P2P4M** corespunzătoare și cele 220 de eşantioane

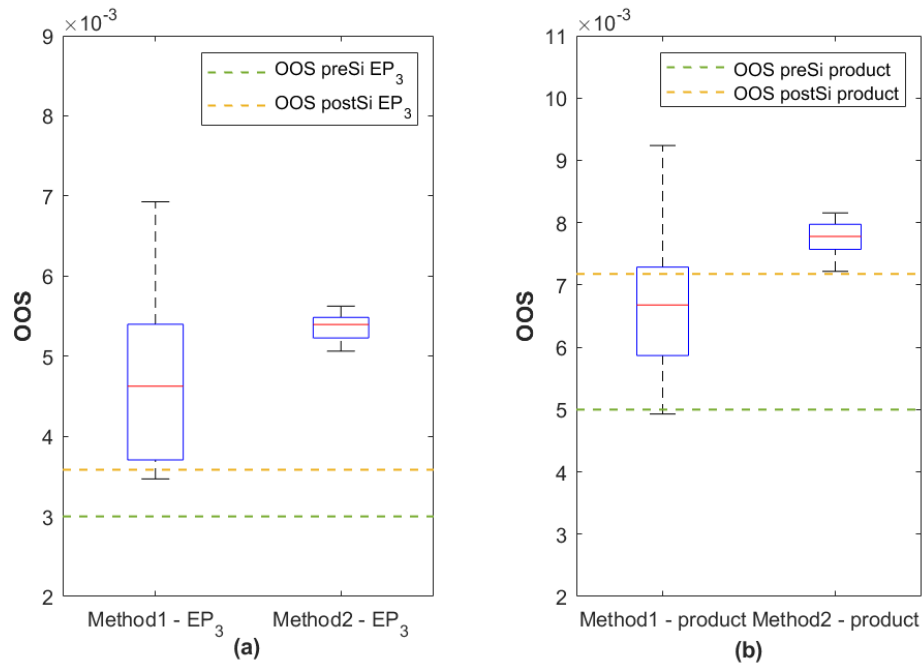


Figura 5.9 Diagrame boxplot ale metricilor OOS calculate cu cele două metode, alături de valorile de referință corespunzătoare, pentru: (a) EP_3 și (b) întregul produs

măsurate disponibile ale PCM_{postSi} . În continuare, eroarea de ajustare a fost modelată pe baza $distFit$ pentru a se ajunge la numărul dorit de eșantioane EP (în acest caz, 164,129 de eșantioane). Predicțiile de randament ale ambelor metode (fără a lua în considerare tipul special de estimare) au tendința de a fi mai aproape de referința ideală considerată (adică măsurătorile postSi OOS), decât de OOS bazată pe simulări, dar algoritmul propus de predicție a randamentului prezintă un comportament stabil, iar pierderea rezultată se află în marjele de siguranță.

Capitolul 6

Concluzii

Capitolul 6 trasează concluziile finale și subliniază contribuțiile originale ale acestei cercetări, împreună cu perspectivele de lucru viitoare.

6.1 Obiective Generale și Rezultate

Această cercetare a fost dedicată studiului evaluării variației procesului de fabricație în analiza de proiectare a circuitelor, prin aplicarea unor abordări de învățare automată. Obiectivul principal a fost dezvoltarea unei metodologii exhaustive pentru o evaluare precisă a impactului variației procesului asupra performanțelor de proiectare a circuitelor, cât mai devreme posibil în fluxul de dezvoltare, urmată de aplicarea acesteia în diverse domenii de cercetare ale CI, cum ar fi analiza sensibilității performanțelor CI în funcție de variația procesului, diagnosticarea inexactităților din modelul de simulare al dispozitivului sau îmbunătățirea predicției randamentului ținând cont de variația tehnologică.

Metodologia **P2P4M** reprezintă o metodologie eficientă și automatizată de modelare a relației dintre parametrii de performanță ai circuitelor (EP) și variațiile procesului tehnologic (măsurate prin intermediul PCM), în etapa preSi. Aceasta conectează verificarea preSi și validarea postSi în ceea ce privește variația procesului, indiferent de distribuția datelor și de configurația corelației, pentru a depăși limitările metodelor actuale. În plus, reprezintă singura metodologie disponibilă capabilă să stabilească relația matematică dintre EP și PCM în faza preSi. *Metamodelele* de regresie fiabile aferente fiecărui EP rezultate din metodologie sunt capabile să exprime atât influența funcțională, cât și cea statistică a parametrilor tehnologici asupra performanțelor circuitului. Astfel, aceasta permite o imagine instantanee și precisă a comportamentului performanțelor circuitelor atunci când apar schimbări tehnologice, fără a fi nevoie de simulări suplimentare sau de măsurători postSi, deoarece este capabilă să se adapteze imediat la distribuțiile PCM. Metodologiile axate pe date sunt aplicabile la aproape orice CI care implică variabile continue, atunci când este posibilă co-simularea modelului de circuit analogic și a schemelor structurilor PCM. Ele nu necesită experimente noi, ci doar simulări MC standard și eșantioane de măsurători postSi.

Rezultatele metodologiilor propuse în cadrul acestei cercetări permit soluții viabile la cele cinci probleme ale industriei semiconductoare evidențiate încă de la început. Pentru problema migrării de la o fabrică la alta, soluția este simplă; metodologia **P2P4M** este aplicată pe un set de date PCM istorice capabile să caracterizeze fereastra de proces pentru fabrica țintă la un moment dat, iar distribuțiile performanțelor electrice ale circuitului pentru produsul care urmează să fie migrat vor rezulta în avans, permițând astfel predicția randamentului. În ceea ce privește efectul aproximativ al modelului de dispozitiv, o diferență mare între distribuția performanțelor precise și cele măsurate efectiv atunci când se utilizează metodologia **P2P4M** pentru modelarea distribuției poate constitui un indiciu puternic al problemelor de precizie existente în modelele de dispozitiv. După cum s-a precizat anterior, metoda de analiză a sensibilității locale ajută proiectantul să elaboreze un plan de testare DoE specific produsului, rapid și cu un calcul rezonabil, deoarece *metamodelele* antrenate, prin intermediul metodei

de analiză a sensibilității globale, sunt capabile să furnizeze informațiile necesare cu privire la setul limitat de PCM influenți. În mod similar, pe lângă precizarea pierderii de randament parametric datorată variației procesului cu ajutorul metodelor de estimare a randamentului introduse, relația dintre performanța circuitului și variația procesului încapsulată în *metamodelle* poate fi utilizată pentru a determina cu ușurință parametrul de variație a procesului care influențează scăderea performanței CI, rezolvând astfel problema analizei cauzei fundamentale ale defectelor. Și nu în ultimul rând, verificarea modelului de CI cu variația procesului poate fi efectuată prin utilizarea metodei de verificare a modelului propuse, care leagă disparitățile de distribuție ale performanțelor de disparitățile omoloage din PCM influenți, oferind astfel o examinare suficientă.

6.2 Contribuții Originale

Principalele contribuții originale ale autorului acestei cercetări (metodologii și concepte) sunt rezumate în cele ce urmează, împărțite pe capitole.

În Capitolul 4:

- Dezvoltarea unei metodologii unificate de selecție a caracteristicilor și de Optimizare Bayesiană a hiperparametrilor pentru antrenarea modelelor de regresie, care se remarcă prin combinarea celor mai bune metrice de selecție a caracteristicilor recomandate de literatura de specialitate (*DistCorr* și *MIC*) cu cadrul de Optimizare Bayesiană, pentru a antrena un model de regresie în rețea neuronală - [40];
 - Aplicarea pe un set de date sintetice controlate, generate de o funcție personalizată cu variabile suplimentare aleatorii (independente), pentru a permite un studiu comparativ cu căutarea în grilă, din punct de vedere al performanței;
 - Aplicarea pe un set de date reale generate de un circuit integrat care depinde de un set limitat de parametri necunoscuți, restul parametrilor având o influență mică sau deloc, urmată de un studiu comparativ cu căutarea în grilă;
 - Din cunoștințele noastre, nu există abordări similare găsite în literatura de specialitate;
- Dezvoltarea metodologiei Verification for Manufacturability by Modelling Process Variation - Circuit Performance Dependency (**P2P4M**) pentru modelarea dependențelor funcționale și statistice dintre performanțele circuitelor (EP) și variația procesului de fabricație (monitorizată prin PCM), în etapa de dezvoltare preSi - [6], [38];
 - Aplicarea pe un CI experimental (LDO) a simulărilor MC pentru a obține *metamodelle* optime pentru fiecare EP studiat, care înglobează subsetul de PCM influenți;

- Un studiu de fiabilitate și coerență a metodologiei **P2P4M**, ilustrat prin rezultate experimentale obținute pe un produs CI real;
- Din cunoștințele noastre, reprezintă singura metodă disponibilă care determină relația dintre EP și PCM sub o formă matematică în etapa preSi;
- Dezvoltarea unui cadru de predicție a distribuțiilor EP postSi pe baza *metamodelor P2P4M* (care reflectă modelarea comportamentului performanțelor circuitului în funcție de variația procesului tehnologic) și o fereastră de referință a procesului - [6];
 - Aplicarea pe un CI analogic, pentru estimarea rapidă a distribuțiilor EP postSi pe baza distribuției măsurătorilor PCM și validarea acurateții abordării folosind metrici de distribuție multidimensională a similitudinii;

În Capitolul 5:

- Dezvoltarea unei metodologii de analiză a sensibilității globale cu variația procesului pentru identificarea și clasificarea celor mai importanți factori PCM, pe baza metricilor de corelație - [37];
 - Un studiu comparativ al metricilor de corelație *DistCorr*, *MIC* și Pearson, subliniind limitele acestora;
 - Aplicarea pe simulările MC clasice ale unui produs de CI pentru determinarea sensibilității performanțelor circuitului la variațiile procesului, prin obținerea unui subset clasificat de PCM influenți;
- Elaborarea unei metodologii de analiză a sensibilității locale cu variația procesului, bazată pe metoda derivatelor parțiale aplicată pe *metamodelle P2P4M*, pentru determinarea sensibilităților locale ale performanțelor circuitelor în colțurile procesului și a punctului de sensibilitate maximă în fereastra de variație a procesului - [42];
 - Aplicarea pe un set de date preSi ale unui produs CI pentru a dovedi comportamentul metodologiei și pentru a asista proiectantul de CI în personalizarea unui DoE orientat pe produs;
- Dezvoltarea unei metodologii de verificare a modelului de simulare pentru examinarea adecvată a impactului variației procesului asupra disparităților distribuțiilor performanțelor circuitelor, o soluție alternativă semi-formală pentru a evalua variația inerentă a procesului care cauzează probleme de acoperire - [12];
 - Aplicarea pe CI analogic, prin utilizarea distribuțiilor preSi și postSi pentru a identifica EP care prezintă discrepanțe de distribuție, urmată de clasificarea acestora ca fiind critice și necritice și analizarea distribuțiilor PCM influenți;

- Dezvoltarea metodologiei de predicție a randamentului pentru calcularea randamentului parametric al distribuțiilor normale într-un stadiu incipient, bazată în întregime pe simulări MC preSi - [41];
 - Aplicarea pentru predicția multivariată a randamentului unui produs CI, prin utilizarea simulărilor MC clasice și ilustrarea rezultatelor în comparație cu un reper predefinit;
- Dezvoltarea predicției parametrice a randamentului cu variația procesului, o versiune îmbunătățită a metodologiei prezentate anterior pentru a se adapta și distribuțiilor non-normale ale parametrilor PCM - [6];
 - Aplicarea pentru predicția parametrică multivariată a randamentului unui produs CI influențat de PCM care prezintă distribuții normale și non-normale, pe baza unui număr limitat de plachete din două loturi de producție.

6.3 Lista Publicațiilor Originale

1. **Elena-Diana Șandru**, A. Buzo, H. Cucu, și C. Burileanu. Recent Experiments and Findings in Baby Cry Classification. În *Fratu O., Militaru N., Halunga S. (eds) Future Access Enablers for Ubiquitous and Intelligent Infrastructures. FABULOUS 2017. Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering*, 241:253–360, Iulie 2018, ISI WOS: 000481658200037, DOI: 10.1007/978-3-319-92213-3_37 [39].
2. **Elena-Diana Șandru** și E. David. Unified Feature Selection and Hyperparameter Bayesian Optimization for Machine Learning based Regression. În *Proceedings of the International Symposium on Signals, Circuits and Systems (ISSCS)*, paginile 1–5, Iași (România), Iulie 2019, ISI WOS: 000503459500003, DOI: 10.1109/ISSCS.2019.8801728 [40].
3. **Elena-Diana Șandru**, C. Burileanu, E. David, A. Buzo, și G. Pelz. Modeling the Dependencies between Circuit and Technology Parameters for Sensitivity Analysis using Machine Learning Techniques. În *Proceedings of the 16th International Conference on Synthesis, Modeling, Analysis and Simulation Methods and Applications to Circuit Design (SMACD)*, paginile 237–240, Lausanne (Elveția), Iulie 2019, ISI WOS: 000503265100060, DOI: 10.1109/SMACD.2019.8795266.
4. **Elena-Diana Șandru**, E. David, și G. Pelz. Pre-Silicon Yield Estimation using Machine Learning Regression. În *Proceedings of the 26th IEEE International Conference on Electronics Circuits and Systems (ICECS)*, paginile 103–104, Genova (Italia), November 2019, ISI WOS: 000534573400028, DOI: 10.1109/ICECS46596.2019.8964997 - **Best Poster Award** [41].

5. **Elena-Diana Șandru**, E. David, și G. Pelz. Machine Learning-Based Local Sensitivity Analysis of Integrated Circuits to Process Variations. În *Proceedings of the 27th IEEE International Conference on Electronics Circuits and Systems (ICECS)*, paginile 1–2, Glasgow (Scoția), November 2020, ISI WOS: 000612696300171, DOI: 10.1109/ICECS49266.2020.9294956 - **Best Presentation Award** [42].
6. I. Kovacs, M. Țopa, C. Pop, **Elena-Diana Șandru**, A. Buzo, și G. Pelz. Correlating Electrical and Process Parameters for Yield Detractors' Detection. In *Proceedings of the 14th International Symposium on Electronics and Telecommunications (ISETC)*, paginile 1–4, Timișoara (România), November 2020, ISI WOS: 000612681000093, DOI: 10.1109/ISETC50328.2020.9301121 [12].
7. **Elena-Diana Șandru**, C. Burileanu, E. David, și G. Pelz. On the Robustness of the Methodology for Modelling the Dependencies between Circuit and Technology Parameters of Integrated Circuits. În *University POLITEHNICA of Bucharest Scientific Bulletin, Series C: Electrical Engineering and Computer Science*, 2021, 83(4):97–110, 2021, **ISSN: 2286-3540** [38].
8. **Elena-Diana Șandru**, E. David, I. Kovacs, A. Buzo, C. Burileanu, și G. Pelz. Modeling the Dependency of Analog Circuit Performance Parameters on Manufacturing Process Variations with Applications in Sensitivity Analysis and Yield Prediction. În *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 41(1):129–142, 2022 - **Q2, IF: 2.807**, ISI WOS: 000732986400014, DOI: 10.1109/TCAD.2021.3054804, **ISSN: 0278-0070** [6].
9. **Elena-Diana Șandru**. General Concepts of Process Variation on Circuit Design and Semiconductor Products Verification. Raport Tehnic Nr. 1, Universitatea POLITEHNICA din București, Mai 2017 [35].
10. **Elena-Diana Șandru**. A Qualitative Analysis of the Process Variation on Circuit Design. State-of-the-Art. Raport Tehnic Nr. 2, Universitatea POLITEHNICA din București, Noiembrie 2017 [36].

6.4 Perspective de Dezvoltare Ulterioare

Cercetările viitoare se pot concentra pe tratarea unora dintre următoarele subiecte, pentru a îmbunătăți abordările propuse:

- Îmbunătățirea metodologiei **P2P4M** în contextul costului computațional, prin adăugarea unui criteriu de oprire iterațiilor de Optimizare Bayesiană atunci când se atinge un anumit minim;

- Aplicarea metodologiei **P2P4M** în calibrarea circuitelor analogice, pentru reglarea proiectării în funcție de variațiile tehnologice, deoarece performanțele din testul de producție pot fi reprezentate ca o funcție a parametrilor de proces și a butoanelor de reglaj;
- Extinderea analizei prin adăugarea altor factori care influențează din punctul de vedere al CI, cum ar fi temperatura, în plus față de variația procesului măsurată prin intermediul parametrilor PCM;
- Integrarea analizei sensibilității globale și locale cu metodologiile de variație a procesului în fazele de dezvoltare a CI, pentru a ajuta proiectantul să stabilească planul de experimente pentru verificarea și validarea post-siliciu (DoE);
- Îmbunătățirea metodologiei de predicție parametrică a randamentului pentru cazurile de produse cu randament ridicat, atunci când sunt implicate cozi de distribuție cu probabilitate foarte mică, prin ajustarea modelării distribuției cu ajutorul tehnicilor de eșantionare bazate pe importanță;
- Integrarea metodologiei de verificare a modelelor de simulare în dezvoltarea de produse CI și îmbunătățirea acestora pentru a permite detectarea elementelor care afectează randamentul pentru a contribui la optimizarea randamentului.

Bibliografie

- [1] Adir, A., Copty, S., Landa, S., Nahir, A., Shurek, G., Ziv, A., Meissner, C., and Schumann, J. (2011). A Unified Methodology for pre-silicon Verification and post-silicon Validation. In *Proceedings of the Design, Automation and Test in Europe Conference and Exhibition (DATE)*, pages 1–6, Grenoble (France).
- [2] Ahmadi, A., Stratigopoulos, H.-G., Huang, K., Nahar, A., Orr, B., Pas, M., Carulli, J.-M., and Makris, Y. (2017). Yield Forecasting Across Semiconductor Fabrication Plants and Design Generations. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 36(12):2120–2133.
- [3] Barragan, M. J. and Leger, G. (2019). Feature Selection and Feature Design for Machine Learning Indirect Test: a Tutorial Review. In *Proceedings of the 16th International Conference on Synthesis, Modeling, Analysis and Simulation Methods and Applications to Circuit Design (SMACD)*, pages 237–240, Lausanne (Switzerland).
- [4] Brochu, E., Cora, V. M., and de Freitas, N. (2010). A tutorial on Bayesian Optimization of Expensive Cost Functions, with Application to Active User Modeling and Hierarchical Reinforcement Learning. <https://arxiv.org/abs/1012.2599>.
- [5] Cacuci, D. G., Ionescu-Buhoar, M., and Navon, I. M. (2005). *Sensitivity and Uncertainty Analysis, Volume II*. Taylor & Francis.
- [6] Sandru, E.-D., David, E., Kovacs, I., Buzo, A., Burileanu, C., and Pelz, G. (2022). Modeling the Dependency of Analog Circuit Performance Parameters on Manufacturing Process Variations with Applications in Sensitivity Analysis and Yield Prediction. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 41(1):129–142.
- [7] Director, S., Strojwas, A. J., and Maly, W. (1989). *VLSI Design for Manufacturing: Yield Enhancement*. Kluwer Academic Publishers, Norwell, MA (USA).
- [8] Durrandeab, N., Ginsbourgerc, D., Roustantb, O., and Carrarod, L. (2013). ANOVA kernels and RKHS of zero mean functions for model-based sensitivity analysis. *Journal of Multivariate Analysis*, 115(1):57–67.
- [9] Gong, F., Shi, Y., Yu, H., and Yu, H. (2014). Variability-aware Parametric Yield Estimation for Analog/Mixed-signal Circuits: Concepts, Algorithms and Challenges. *IEEE Design & Test*, 31(4):6–15.
- [10] Haykin, S. (2009). *Neural Networks and Learning Machines*. Pearson.
- [11] Kovacs, I., Topa, M., Buzo, A., and Pelz, G. (2017). An Accurate Yield Estimation Approach for Multivariate Non-normal Data in Semiconductor Quality Analysis. In *Proceedings of the 14th International Conference on Synthesis, Modeling, Analysis and Simulation Methods and Applications to Circuit Design (SMACD)*, Taormina (Italy).

- [12] Kovacs, I., Topa, M., Pop, C., Şandru, E.-D., Buzo, A., and Pelz, G. (2020). Correlating Electrical and Process Parameters for Yield Detractors' Detection. In *Proceedings of the 27th International Symposium on Electronics and Telecommunications (ISETC)*, pages 1–4, Timisoara (Romania).
- [13] Kuhn, K. J., Giles, M. D., Becher, D., Kolar, P., Kornfeld, A., Kotlyar, R., Ma, S. T., Maheshwari, A., and Mudanai, S. (2011). Process Technology Variation. *Proceedings of the IEEE Transactions on Electron Devices*, 58(8):2197—2208.
- [14] Kumar, J. A., Ahmadyan, S. N., and Vasudevan, S. (2014). Efficient Statistical Model Checking of Hardware Circuits with Multiple Failure Regions. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 33(6):945–958.
- [15] Liu, Q. and Wu, Y. (2012). *Supervised Learning*, chapter Supervised Learning, pages 3349–3351. Encyclopedia of the Sciences of Learning. Springer.
- [16] Miao, J. and Niu, L. (2016). A survey on feature selection. *Procedia Computer Science*, 91:919–926.
- [17] Mitra, S., Seshia, S. A., and Nicolici, N. (2010). Post-silicon Validation Opportunities, Challenges and recent Advances. In *Proceedings of the 47th Design Automation Conference (DAC)*, pages 12–17, Anaheim, CA (USA).
- [18] Mittal, S. (2016). A Survey of Architectural Techniques for Managing Process Variation. *ACM Computing Surveys (CSUR)*, 48(4).
- [19] Pieper, K.-W. and Gontro, E. (2011). An Effective Method for Solving the Covariance Equation for Statistical Modeling. In *Proceedings of 2011 Semiconductor Conference Dresden*, pages 1–4, Dresden (Germany).
- [20] Reshef, D. N. and *et. all* (2011). Detecting Novel Associations in Large Data Sets. *Science*, 334(6062):1218–1224.
- [21] Schemmert, W. and Zimmer, G. (1974). Threshold-voltage Sensitivity of Ion-implanted MOS Transistors due to process Variations. *Electronica Letters*, 10(9):151–1524.
- [22] Seligman, E., Schubert, T., Achutha, M. V., and Kumar, k. (2015). *Basic Formal Verification Algorithms*, chapter 2, pages 23–47. Formal Verification - An Essential Toolkit for Modern VLSI Design. Morgan Kaufmann.
- [23] Shockley, W. (1961). Problems related to p-n Junctions in Silicon. *Solid-State Electronics*, 2:35–67.
- [24] Snedecor, G. W. and Cochran, W. G. (1989). *Statistical Methods*. Iowa State University Press, Ames, IA (USA), 8 edition.
- [25] Snoek, J., Larochelle, H., and Prescott Adams, R. (2012). Practical Bayesian Optimization of Machine Learning Algorithms. In *Proceedings of the 25th International Conference on Neural Information Processing Systems (NIPS)*, Lake Tahoe, NV (Spain).
- [26] Sobe, U., Roach, K.-H., and Mörtl, D. (2007). Simulation and Analysis of Analog Circuit and PCM (Process Control Monitor) Test Structures in Circuit Design. In *Dresden Workshop on Circuit and System Design 2007*, Dresden (Germany).

- [27] Stanislavljevic, D. and Spitzer, M. (2015). A Review of Related Work on Machine Learning in Semiconductor Manufacturing and Assembly Lines. In *Proceedings of the 15th International Conference on Knowledge Technologies and Data-driven Business (i-KNOW)*, Graz (Austria).
- [28] Stratigopoulos, H.-G. (2018). Machine Learning Applications in IC Testing. In *Proceedings of the 23rd IEEE European Test Symposium (ETS)*, Bremen (Germany).
- [29] Szekely, G., Rizzo, M., and Bakirov, N. K. (2007). Measuring and testing dependence by correlation of distances. *The Annals of Statistics*, 35(6):2769–2794.
- [30] Tang, J., Alelyani, S., and Liu, H. (2014). *Feature Selection for Classification: a Review*. CRC Press.
- [31] Xanthopoulos, C., Huang, K., Ahmadi, A., Kupp, N., Carulli, J., Nahar, A., Orr, B., Pass, M., and Makris, Y. (2019). *Gaussian Process-Based Wafer-Level Correlation Modeling and Its Applications*, chapter 5, pages 119–173. Machine Learning in VLSI Computer-Aided Design. Springer.
- [32] Zhang, Y., Sankaranarayanan, S., Somenzi, F., Chen, X., and Abraham, E. (2013). From Statistical Model Checking to Statistical Model Inference: Characterizing the Effect of Process Variations in Analog Circuits. In *Proceedings of the 2013 IEEE/ACM International Conference on Computer-Aided Design (ICCAD)*, San Jose, CA (USA).
- [33] Zhou, X. and Lin, H. (2008a). *Global Sensitivity Analysis*, chapter Global Sensitivity Analysis, page 787. Encyclopedia of GIS. Springer.
- [34] Zhou, X. and Lin, H. (2008b). *Local Sensitivity Analysis*, chapter Local Sensitivity Analysis, pages 1130–1131. Encyclopedia of GIS. Springer.
- [35] Şandru, E.-D. (2017a). A Qualitative Analysis of the Process Variation on Circuit Design. State-of-the-Art. Technical Report No. 2, University POLITEHNICA of Bucharest.
- [36] Şandru, E.-D. (2017b). General Concepts of Process Variation on Circuit Design and Semiconductor Products Verification. Technical Report No. 1, University POLITEHNICA of Bucharest.
- [37] Şandru, E.-D., Burileanu, C., David, E., Buzo, A., and Pelz, G. (2019a). Modeling the Dependencies between Circuit and Technology Parameters for Sensitivity Analysis using Machine Learning Techniques. In *Proceedings of the 16th International Conference on Synthesis, Modeling, Analysis and Simulation Methods and Applications to Circuit Design (SMACD)*, pages 237–240, Lausanne (Switzerland).
- [38] Şandru, E.-D., Burileanu, C., David, E., and Pelz, G. (2021). On the Robustness of the Methodology for Modelling the Dependencies between Circuit and Technology Parameters of Integrated Circuits. *University POLITEHNICA of Bucharest Scientific Bulletin, Series C: Electrical Engineering and Computer Science*, 83(4):97–110.
- [39] Şandru, E.-D., Buzo, A., Cucu, H., and Burileanu, C. (2018). Recent Experiments and Findings in Baby Cry Classification. *Fratu O., Militaru N., Halunga S. (eds) Future Access Enablers for Ubiquitous and Intelligent Infrastructures. FABULOUS 2017. Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering*, 241:253–360.

- [40] Şandru, E.-D. and David, E. (2019). Unified Feature Selection and Hyperparameter Bayesian Optimization for Machine Learning based Regression. In *Proceedings of the International Symposium on Signals, Circuits and Systems (ISSCS)*, pages 1–5, Iaşi (Romania).
- [41] Şandru, E.-D., David, E., and Pelz, G. (2019b). Pre-Silicon Yield Estimation using Machine Learning Regression. In *Proceedings of the 26th IEEE International Conference on Electronics Circuits and Systems (ICECS)*, pages 103–104, Genoa (Italy).
- [42] Şandru, E.-D., David, E., and Pelz, G. (2020). Machine Learning-Based Local Sensitivity Analysis of Integrated Circuits to Process Variations. In *Proceedings of the 27th IEEE International Conference on Electronics Circuits and Systems (ICECS)*, pages 1–2, Glasgow (Scotland).