



**UNIVERSITATEA POLITEHNICA
DIN BUCUREȘTI**



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

Decizie nr. 1062 din 10-07-2023

**REZUMAT TEZĂ
DE DOCTORAT**

Georgian NICOLAE

**APLICAȚII DE ÎNVĂȚARE AUTOMATĂ ÎN PROIECTAREA
TRANZISTOARELOR MOSFET DE PUTERE**

**MACHINE LEARNING APPLICATIONS IN POWER MOSFET
DESIGN**

COMISIA DE DOCTORAT

Prof. Dr. Ing. Mihai CIUC Universitatea Politehnica din București	Președinte
Prof. Dr. Ing. Corneliu BURILEANU Universitatea Politehnica din București	Conducător de doctorat
Prof. Dr. rer. nat. Georg PELZ Infineon Technologies AG & Univ. Duisburg-Essen	Referent
Prof. Dr. Ing. Marina ȚOPA Universitatea Tehnică din Cluj-Napoca	Referent
Prof. Dr. Ing. Cristian RAVARIU Universitatea Politehnica din București	Referent

BUCUREȘTI 2023

Cuprins

1	Introducere	1
1.1	Proiectarea viitoarelor MOSFET-uri de putere	1
1.2	Scopul tezei	2
1.3	Motivația	2
1.4	Conținutul tezei	2
2	Lucrări de referință și noțiuni teoretice	3
2.1	Analiza cu elemente finite a MOSFET-ului de putere	3
2.1.1	Simularea cu elemente finite	3
2.1.2	Limitări electro-termice ale MOSFET-urilor de putere	3
2.1.3	Considerații practice în simularea cu elemente finite	3
2.2	Reglarea automată a parametrilor	4
2.3	Modele de învățare automată în semiconductori	4
2.3.1	Aplicarea tehnicilor de învățare automată	4
2.3.2	Aplicații ale modelelor de regresie	4
2.4	Optimizarea automată a proiectării	4
3	Simularea eficientă în timp a MOSFET-urilor de putere	5
3.1	Introducere	5
3.2	Reducerea timpului de simulare prin automatizare	5
3.2.1	Proiectul generic al MOSFET-ului de putere	6
3.2.2	Instrument pentru reglarea parametrilor de simulare	6
3.2.3	Mediul automat de simulare	8
3.3	Estimarea R_{on} pe bază de metamodel	8
3.3.1	Prezentare generală	8
3.3.2	Setul de date de simulare	8
3.3.3	Antrenarea metamodelului pentru predicția R_{on}	8
3.3.4	Schimbările discrete în proiectarea MOSFET-ului de putere	9
3.3.5	Evaluarea performanțelor metamodelului	9
3.4	Rezultate experimentale	9
3.4.1	Reglarea automată a parametrilor – Scenariu experimental	9
3.4.2	Studiu de caz 1: Metamodel pentru <i>Tehnologia A</i>	10

3.4.3	Studiu de caz 2: Metamodel pentru <i>Tehnologia B</i>	11
3.5	Rezumat și concluzii	12
4	Aplicații ale metamodelelor pentru MOSFET-uri de putere	13
4.1	Introducere	13
4.2	Analiza sensibilității	13
4.3	Analiza proiectării experimentelor	14
4.4	Îmbunătățirea randamentului parametric din producție	16
4.4.1	Provocări ale estimării randamentului folosind metamodelle . . .	16
4.4.2	Metoda propusă pentru estimarea randamentului parametric . .	16
4.4.3	Scenariu experimental	16
4.5	Rezumat și concluzii	17
5	Proiectarea rentabilă a MOSFET-urilor de putere	18
5.1	Introducere	18
5.2	Metoda propusă de optimizare a proiectării	18
5.2.1	Prezentare generală	18
5.2.2	Considerații asupra folosirii metamodelelor in optimizarea auto- mată proiectării	19
5.2.3	Formularea problemei de optimizare	20
5.2.4	Optimizarea proiectării pentru o funcție R_{on} continuă	21
5.2.5	Abordarea discontinuităților	22
5.2.6	Validarea structurii optimale	22
5.3	Rezultate experimentale	23
5.3.1	Studiu de caz 1: Optimizare pentru <i>Technologia A</i>	23
5.3.2	Studiu de caz 2: Optimizare pentru <i>Tehnologia B</i>	23
5.4	Rezumat și concluzii	26
6	Concluzii generale	27
6.1	Obiective și rezultate	27
6.2	Contribuții originale	28
6.3	Lista de lucrări originale	29
6.4	Lista de rapoarte tehnice	30
6.5	Perspective de dezvoltare ulterioară	30
	Bibliografie	31

Capitolul 1

Introducere

Scopul acestei teze este de a efectua o investigație a tehnicilor de proiectare utilizate în prezent și de a oferi soluții pentru îmbunătățirea acestor tehnici în vederea maximizării performanțelor dispozitivului, reducând în același timp costurile asociate. Primul obiectiv este de a reduce timpul de simulare necesar pentru analizele complexe ale MOSFET-urilor de putere. Un al doilea obiectiv este de a determina un compromis între costul și performanța MOSFET-ului de putere proiectat.

1.1 Proiectarea viitoarelor MOSFET-uri de putere

Simularea cu elemente finite este un instrument important în evaluarea noilor descoperiri științifice. O simulare relevantă acoperă procesele fizice care influențează performanța MOSFET-ului. Acest aspect trebuie să fie abordat cu atenție înainte de a utiliza un instrument de simulare specific. În cazuri speciale, simulatorul poate fi îmbunătățit pentru a modela noi efecte fizice în structura tranzistorului. Determinarea parametrilor de performanță poate necesita o prelucrare suplimentară a rezultatelor.

După alegerea unui simulator adecvat, următorul pas este reproducerea rezultatelor prezentate în studiile de cercetare. Este dezvoltat un proiect de MOSFET care prezintă îmbunătățiri structurale. Apoi, această structură este evaluată prin simulare. Limitările de natură teoretică sunt, de asemenea, abordate în simulare.

În acest moment, noul tipul de dispozitive este în sfârșit aprobat pentru fabricație. Inginerii de proiectare și de simulare lucrează în strânsă colaborare pentru a proiecta noi dispozitive pe baza setului de cerințe de performanță furnizat. Pornind de la un șablon, se efectuează mai multe iterații de proiectare până când se obține un dispozitiv optimal.

Etapa finală constă în ajustarea noului proiect de dispozitiv pentru a asigura fabricarea eficientă a acestuia. Pentru a realiza acest lucru, este necesară o estimare inițială a randamentului în producție.

1.2 Scopul tezei

Obiectivul principal este îmbunătățirea procesului de proiectare pentru generațiile viitoare de MOSFET-uri de putere. În secțiunea anterioară a fost prezentat un rezumat concis al acestui subiect. Prin analiza acestuia, putem identifica principalele dificultăți ale metodologiei generale: (1) Configurarea mediului de simulare necesită un efort și costuri considerabile; (2) Pentru a efectua simulări, proiectul MOSFET trebuie să fie ajustat manual de numeroase ori; (3) Simulările cu elemente finite, care sunt necesare pentru a determina performanța unui proiect MOSFET, necesită efort manual și de calcul și necesită mult timp; (4) Fazele inițiale ale procesului de proiectare a noilor MOSFET-uri sunt abordate cu atenție de către inginerul de proiectare pe baza modelării proceselor fizice; (5) Estimarea randamentului inițial pentru noile MOSFET-uri influențează numărul de serii de cipuri de testare.

1.3 Motivația

După cum s-a menționat în secțiunile anterioare, procesul de proiectare a unor noi tipuri de MOSFET-uri prezintă diverse provocări. Procesul de proiectare este în mare parte manual, chiar dacă simularea în sine este automatizată, deoarece variațiile de proiectare sunt manuale până în prezent. Acestea pot fi depășite prin aplicarea conceptelor de învățare automată. Tehnicile bazate pe învățarea automată au fost deja utilizate cu succes într-o mare varietate de sarcini diferite legate de semiconductori. Următoarele premise servesc drept bază pentru metodele propuse în această teză: *A.* Volumul de date limitat; *B.* Consistența datelor; *C.* Sarcini de rutină; *D.* Alternative de modelare.

1.4 Conținutul tezei

Capitolul 2 prezintă elementele fundamentale ale MOSFET-ului de putere și modelarea acestuia cu ajutorul simulării cu elemente finite, o trecere în revistă a literaturii în ceea ce privește metodele de reglare automată a parametrilor, conceptele generale de învățare automată și o trecere în revistă a optimizării automate a proiectării în domeniul semiconductoarelor.

Metodele propuse în capitolul 3 au ca scop îmbunătățirea timpului total de simulare necesar pentru o analiză avansată a MOSFET-urilor de putere folosind metamodele, în timp ce capitolul 4 prezintă aplicațiile imediate ale metamodelor.

Capitolul 5 se concentrează pe optimizarea automată a proiectării MOSFET-urilor de putere în ceea ce privește specificațiile de performanță. Prin urmare, metodele propuse realizează o proiectare rentabilă a tranzistorului.

Capitolul 6 formulează concluzii generale privind metodele propuse, descrie impactul subiectului actual și ilustrează principalele contribuții ale autorului.

Capitolul 2

Lucrări de referință și noțiuni teoretice

2.1 Analiza cu elemente finite a MOSFET-ului de putere

Modelarea numerică a fenomenelor termice și electromagnetice din dispozitivele semiconductoare este o sarcină dificilă, deoarece necesită identificarea unor soluții pentru mai multe probleme numerice. În plus, neliniaritățile modelelor ridică și mai mult nivelul de dificultate.

2.1.1 Simularea cu elemente finite

Simulatoarele electrotermice [Rin01, PJS08, BIMR18] sunt instrumente create special pentru a determina temperatura unui dispozitiv la un anumit moment în timp ce acesta funcționează. Estimarea temperaturii interne maxime a dispozitivului este un obiectiv pentru a determina zona de funcționare sigură, dar există considerații suplimentare care pot dezvălui, de asemenea, stresul termic exercitat asupra structurilor relevante [Nic18].

2.1.2 Limitări electro-termice ale MOSFET-urilor de putere

Aria sigură de funcționare (ASF) se referă la o secțiune a curbei caracteristice $V_{DS} - I_D$ care denotă gama de tensiuni și curenți de funcționare la care un MOSFET de putere poate fi utilizat fără riscul de a provoca distrugerea componentei. Aria sigură de funcționare pe termen scurt și Aria sigură de funcționare pe termen lung sunt cele două categorii de ASF [HP05].

2.1.3 Considerații practice în simularea cu elemente finite

Simularea cu elemente finite determină o aproximare numerică a soluției reale. În general, va exista o eroare de aproximare care variază în funcție de structura ochiurilor de plasă, deoarece determinarea rezultatului simulării este echivalentă cu rezolvarea unui sistem de ecuații.

2.2 Reglarea automată a parametrilor

În [Hoo12] sunt prezentate metodele utilizate, în literatură, pentru *reglarea parametrilor*. Autorii descriu că majoritatea abordărilor se încadrează în trei clase de algoritmi: *Racing Procedures*, *ParamILS* și *Sequential Model-Based Optimisation*. Apoi sunt prezentate alte abordări în ceea ce privește sarcinile specifice aplicațiilor.

2.3 Modele de învățare automată în semiconductori

Abordările de învățare automată pentru creșterea eficienței procesului de fabricație a semiconductoarelor, precum și analiza de date aferentă, oferă avantaje semnificative și au câștigat mult interes în cercetare atât la nivel de industrie, cât și în mediul academic [ICFQ93][Wan17]. În ultimii ani, au fost propuse mai multe tehnici de învățare automată pentru rezolvarea sarcinilor legate de semiconductori [HHL21].

2.3.1 Aplicarea tehnicilor de învățare automată

În această lucrare, metodele propuse se încadrează în categoria *Învățare supervizată*, *Regresie*, conform [Mur12]. Tehnicile de regresie presupun determinarea unei funcții pentru maparea variabilelor de intrare într-o variabilă continuă de ieșire. Prima cerință este de a construi set de date constituit din perechi intrare-ieșire.

2.3.2 Aplicații ale modelelor de regresie

Aproximarea modelelor sau metamodelarea reprezintă o tehnică de reducere a timpului de execuție a simulărilor care necesită un calcul intensiv. În plus, sarcinile complexe, care necesită un număr mare de simulări costisitoare din punct de vedere computațional, pot fi realizate eficient prin utilizarea tehnicilor de metamodelare.

2.4 Optimizarea automată a proiectării

Metodele propuse în literatura de specialitate se încadrează în mare parte în clasa de optimizare fără calcul de derivate. Comparativ cu optimizarea deterministă, aceasta este preferată de autori deoarece este mai puțin dificil de aplicat. Aceste tehnici pot fi clasificate pe baza dacă utilizării, sau nu, a unui model surrogat. În literatura de specialitate se preferă optimizarea cu ajutorul unui model surrogat. Modelul surrogat din lucrările prezentate are la bază fie pe procese gausiene, fie pe rețele neurale.

Capitolul 3

Simularea eficientă în timp a MOSFET-urilor de putere

3.1 Introducere

Performanța necesară a MOSFET-urilor de putere este într-o continuă creștere datorită utilizării acestora în sursele de energie regenerabilă și în vehiculele electrice. Prin urmare, proiectarea următoarei generații de MOSFET-uri de putere a devenit mult mai dificilă. Simularea este o componentă cheie, deoarece procesul de proiectare începe cu modelarea tranzistorului folosind analiza cu elemente finite. Asigurarea unei precizii ridicate a simulării este o cerință pentru obținerea unor dispozitive de înaltă performanță. Apoi, trebuie abordat cu atenție compromisul dintre acuratețe și timpul de simulare.

3.2 Reducerea timpului de simulare prin automatizare

Proiectarea semiconductoarelor discrete implică utilizarea unor instrumente de proiectare asistată de calculator (CAD) de înaltă calitate. Dintre instrumentele CAD, simulatoarele cu elemente finite au o mare importanță în proiectarea de noi dispozitive și tehnologii. Configurarea simulatorului pentru sarcina specifică trebuie efectuată înainte de a efectua experimentele. Acest proces este definit ca reglarea parametrilor de simulator.

Selecția parametrilor, ca parte a simulării, constă într-un proces manual iterativ realizat de inginerii de simulare. Experiența anterioară a expertului și corelația acesteia cu problema curentă sunt principalii factori ai duratei acestei sarcini. Un inginer de simulare cu experiență va fi capabil să optimizeze acest proces manual de încercare și eroare prin alegerea empirică a unui bun set de parametri.

Abordarea pentru realizarea unei sarcini bazate pe simulare trebuie să fie discutată pentru a evalua timpul total de simulare. Prin urmare, o analiză bazată pe simulare constă în patru etape principale, după cum urmează: (1) Configurarea mediului de simulare; (2) Proiectarea experimentelor; (3) Executarea simulării; (4) Prelucrarea rezultatelor.

3.2.1 Proiectul generic al MOSFET-ului de putere

Înainte de a configura mediul de simulare, este important să prezentăm structura MOSFET-ului de putere. Fig. 3.1 ilustrează o secțiune transversală verticală a unei structuri 3D generice a unui pachet MOSFET de putere, redusă la 8 componente (straturi).




Figura 3.1 Secțiune transversală verticală a dispozitivului [NBC⁺22]

Fiecare strat al pachetului MOSFET este definit prin lungime, lățime, grosime și proprietăți ale materialului. În scopul simplificării, se presupune că fiecare strat este omogen. Tabelul 3.1 prezintă parametrii de proiectare disponibili pentru inginer. Parametrii de lungime și lățime sunt definiți pentru chip și clip, în timp ce grosimea este definită pentru fiecare strat.

Tabel 3.1 Parametrii de proiectare [NBF⁺21]

Nr.	Denumirea parametrului	Nr.	Denumirea parametrului
1	Clip Width	6	Clip Thickness
2	Clip Length	7	Top Metal 1 Thickness
3	Chip Width	8	Top Metal 2 Thickness
4	Chip Length	9	Top Solder Thickness
5	Chip Thickness	10	Bottom Solder Thickness

3.2.2 Instrument pentru reglarea parametrilor de simulare

În ceea ce privește cazul de față, simulatorul are doi parametri care trebuie să fie configurați. Acești doi parametri sunt setări ale rețelei de elemente finite. Un parametru este responsabil pentru densitatea elementelor finite, iar celălalt parametru definește volumul maxim al unui element finit. Dimensiunea elementelor finite este foarte importantă, deoarece reprezintă un compromis între precizia rezultatelor și timpul de simulare.

O prezentare generală a metodei propuse este ilustrată în Fig. 3.5. Există două blocuri funcționale principale: *Experiment Planner* și *Simulator Framework*.

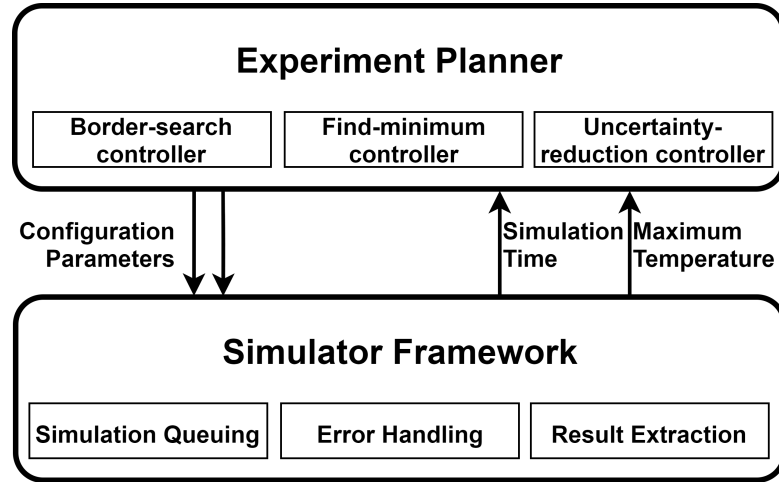


Figura 3.5 Diagrama metodei propuse [NBB⁺20]

Există trei obiective principale care trebuie îndeplinite de către *Experiment Planner*: (i) determinarea zonei de convergență în funcție de parametrii de configurare; (ii) determinarea minimelor globale sau locale ale timpului de simulare în zona de convergență; (iii) descrierea comportamentului rezultatelor în zona de convergență.

Înainte de a descrie algoritmul, trebuie definiți câțiva factori: N este numărul de simulări paralele; k este condiția de oprire; n_{bs} este numărul de simulări alocate controlerului *Border-search*; n_{fm} este numărul de simulări alocate controlerului *Find-minimum*; n_{ur} este numărul de simulări alocate controlerului *Uncertainty-reduction*.

Algorithm 1: Reglarea automată a parametrilor [NBB⁺20]

Intrare : Spațiul de configurații \mathcal{C}

Ieșire : Spațiul de convergență, Temperatura, Timpul de simulare

- 1 Inițializează N , k , $n_{bs} = 0$, $n_{fm} = 0$, $n_{ur} = N$ și modelul SVM al controlerului *Border-search*;
 - 2 Fiecare controler generează un număr de eșantioane conform n_{bs} , n_{fm} , n_{ur} ;
 - 3 **cât timp** condiția k nu este îndeplinită **execută**
 - 4 *Simulator Framework* rulează simulările și returnează Timpul de simulare, Temperatura și informații despre convergență;
 - 5 Controlerul *Border-search* prezice rezultatele pentru setul de eșantioane și le compară cu rezultatele simulării;
 - 6 Numără toate eșantioanele clasificate incorect: h ;
 - 7 Actualizează numărul de simulări alocate: $n_{bs} = h$, $n_{fm} = \text{floor}(\frac{N-h}{2})$, $n_{ur} = \text{floor}(\frac{N-h}{2})$;
 - 8 Antrenează controlerul pe baza rezultatelor din simulare;
 - 9 Fiecare controler generează un număr de eșantioane conform n_{bs} , n_{fm} , n_{ur} ;
 - 10 **final**
-

3.2.3 Mediul automat de simulare

Funcționalitatea mediului automat de simulare este prezentată după cum urmează. Primul bloc, 2D Chip Layout, generează proiectul 2D pe baza intrărilor sale (lățimea cipului, lungimea cipului, lățimea și lungimea clipului).

Al doilea bloc are rolul de a transpune proiectul 2D în proiectul 3D, generând structura 3D (*package*). Pentru a realiza acest lucru, primul pas este definirea dimensiunii plane a tuturor straturilor existente. Următorul pas este construirea geometriei 3D prin includerea parametrilor de grosime a straturilor și ajustarea formelor în funcție de parametri tehnologici. În final, proprietățile electrotermice ale materialelor sunt atribuite elementelor 3D, iar structura este acum pregătită pentru simulare.

3.3 Estimarea R_{on} pe bază de metamodel

Descrierea formală a metamodelului este reprezentată sub forma funcției $f(X) = R_{on}$, unde $f : \mathbb{R}^N \rightarrow \mathbb{R}$ și X reprezintă vectorul de N parametri de proiectare. Principalul avantaj al metamodelului este timpul redus de inferență. Acesta este semnificativ mai mic decât timpul de simulare cu elemente finite, cu câteva ordine de mărime, pe baza rezultatelor noastre [NCB⁺23].

3.3.1 Prezentare generală

Există trei blocuri funcționale principale în metoda propusă: (1) Proiectarea experimentelor: pornește de la intervalele de parametri de proiectare și de la constrângerile de proiectare și are ca rezultat setul de date de simulare. (2) Antrenarea metamodelului: preia setul de date de simulare din blocul anterior și are ca rezultat metamodelul cu cea mai bună performanță de predicție. (3) Predicția pe baza metamodelului: este etapa finală, în care cel mai bun metamodel este utilizat pentru predicția R_{on} .

3.3.2 Setul de date de simulare

Nu orice combinație de parametri de proiectare conduce la un dispozitiv care poate fi fabricat. Cu toate acestea, simularea acestor combinații de parametri de proiectare este încă posibilă. Prin urmare, toate experimentele prezente în setul de date de simulare trebuie să fie verificate de două ori în ceea ce privește constrângerile de proiectare.

3.3.3 Antrenarea metamodelului pentru predicția R_{on}

În perspectiva curentă, aproximarea funcției R_{on} a parametrilor de proiectare capătă o dimensiune statistică. Funcția de estimare trebuie să aibă o precizie suficientă în comparație cu simularea în ceea ce privește aplicarea metamodelului. Scopul este de

a antrena un metamodel care are o probabilitate scăzută \mathbb{P} de a prezice R_{on} eronate în hiperspațiul valid al parametrilor de proiectare, D . În această lucrare au fost evaluate patru tipuri principale de modele de învățare automată: *Regresie liniară*, *Support Vector Machine (SVM)*, *Gaussian Process*, și *Rețele neurale*.

3.3.4 Schimbările discrete în proiectarea MOSFET-ului de putere

Această teză abordează provocarea de a adapta un metamodel atunci când există schimbări discontinue în proiectarea tranzistorului și include următoarele particularități împreună cu examinarea subiectului. Abordarea noastră constă în divizarea spațiului valid al parametrilor de proiectare în mai multe subspații, pe baza continuității răspunsului, R_{on} .

3.3.5 Evaluarea performanțelor metamodelului

Metrica de evaluare a metamodelului folosită în această lucrare este eroarea relativă maximă (*MRE*), ilustrată în (3.3). Prin urmare, rezultatele predicției pot fi exprimate împreună cu un grad de toleranță, $R_{on} \pm MRE\%$. Acest lucru este foarte important din punct de vedere practic, deoarece inginerii de simulare și de proiectare sunt deja familiarizați cu acest format.

$$MRE[\%] = \max_{X \in D} \left(\frac{|R(X) - \hat{R}(X)|}{R(X)} \times 100 \right) \quad (3.3)$$

unde: X este vectorul n -dimensional al parametrilor de proiectare; $D \subset \mathbb{R}^n$ spațiul valid al parametrilor de proiectare; $R(X)$ este valoarea R_{on} din simulare; $\hat{R}(X)$ este valoarea estimată a lui R_{on} .

3.4 Rezultate experimentale

Pentru început prezentăm un scenariu experimental care ilustrează reducerea timpului de simulare. Pentru antrenarea metamodelului de predicție R_{on} ale dispozitivelor, abordăm două cazuri de utilizare, fiecare dintre acestea prezentând o tehnologie de proiectare.

3.4.1 Reglarea automată a parametrilor – Scenariu experimental

Următoarele experimente sunt efectuate pe o structură de tranzistor cu o suprafață mai mică a cipului. Începem prin a ilustra experimentele în ceea ce privește primul obiectiv: definirea zonei de convergență a parametrilor de configurare. Prin utilizarea controlerului *Border-search* din *Experiment Planner* pentru a determina această zonă, se evită un număr mare de simulări non-convergente. În Fig. 3.16 prezentăm un exemplu de utilizare a controlerului *Border-search* pentru determinarea zonei de convergență. Intrarea controlerului *Border-search* este binară; simularea a fost convergentă sau nu.




Figura 3.16 Spațiul de convergență în funcție de parametri de configurare [NBB⁺20]

Tabelul 3.3 arată că în jur de 90% din configurațiile generate de celelalte două controlere nu sunt convergente. În absența controlerului *Border-search*, doar 10,56% din experimentele efectuate de controlerul *Uncertainty-reduction* sunt convergente. În aceleași condiții, controlerul *Find-minimum* are o performanță similară, majoritatea experimentelor se situează dincolo de zona de convergență. Prin utilizarea controlerului *Border-search*, *Experiment Planner* are o rată de convergență de 81%.

Tabel 3.3 Rata de convergență pentru tipurile de controlere [NBB⁺20]

Controler	Rata de convergență
Uncertainty-reduction	10.65%
Find-minimum	12.25%
Experiment Planner	81%

3.4.2 Studiu de caz 1: Metamodel pentru *Tehnologia A*

Tehnologia A se referă la un MOSFET de putere generic. Acesta manifestă toate caracteristicile descrise în secțiunea 3.2.1. Ca trăsătură specifică, această tehnologie are proprietatea de a fi parametrizată în mod continuu.

Pentru a acoperi spațiul de parametri, au fost efectuate un număr de 1300 de simulări utilizând un mediu de simulare automat. Setul de date este împărțit între 70% de antrenare, 15% de validare și 15% de testare pentru rețeaua neurală, iar pentru celelalte metode de învățare automată, o validare de tip *10 k-fold* [NBF⁺21].

Rezultatele antrenării metamodelului sunt prezentate în tabelul 3.5. După cum se poate observa, dimensiunea stratului complet conectat, indicată de variabila *LayerSize*, a

fost ajustată într-o gamă largă, începând cu 4 noduri și ajungând până la 50 de noduri. Cel mai bun rezultat este obținut cu un strat complet conectat de dimensiunea 40 și cu o antrenare realizată prin *Bayesian regularization*. Pentru acest metamodel, MAE este de 0,00026 *mOhms*, iar eroarea relativă maximă este de 0,14%.

Tabel 3.4 Rezultate pentru Rețeaua Neurală: Valoarea maximă absolută a erorii este prezentată pentru fiecare model antrenat.[NCB⁺23]

No.	LayerSize	Algorithmul de antrenare		
		Levenberg–Marquardt	Bayesian regularization	Scaled Conjugate Gradient
1	4	0.01432	0.01328	0.06964
2	6	0.00803	0.00409	0.03714
3	8	0.00257	0.00265	0.04503
4	10	0.00256	0.00291	0.09026
5	15	0.00163	0.00078	0.05323
6	20	0.00157	0.00045	0.04566
7	25	0.00058	0.00039	0.07499
8	30	0.00074	0.00043	0.06108
9	35	0.00083	0.00048	0.04214
10	40	0.00054	0.00026	0.11500
11	45	0.00051	0.00064	0.07066
12	50	0.00045	0.00042	0.19870

Rezultatele antrenării metamodelului sunt prezentate în tabelul 3.5. După cum se poate observa, cele mai bune rezultate sunt obținute de rețelele neurale, dar și Gaussian Process prezintă rezultate promițătoare.

Tabel 3.5 Evaluarea metamodelului *Technologiei A* [NCB⁺23]

Algoritm	MRE [%]
Neural Networks	0.14
GPR Matern 5/2	0.70
GPR Rational Quadratic	1.13
SVM Cubic Regression	5.58
Linear Regression	74.02

3.4.3 Studiu de caz 2: Metamodel pentru *Tehnologia B*

Pentru *Tehnologia B*, procesul de proiectare implică două tehnici: (i) scalarea geometriei, (ii) ajustarea numărului de *gate fingers*. Prin urmare, rezultatul performanței R_{on} poate fi considerat o funcție discontinuă în punctele în care intervine cel de-al doilea proces. De asemenea, fiind vorba de o tehnologie avansată, timpul de simulare este mai lung în comparație cu *Tehnologia A*.

Experimentele pentru *Tehnologia B* prezintă un set redus de parametri de proiectare pentru a ilustra introduse de discontinuități la un cost minim de timp de simulare. Parametrii 1-5 din tabelul 3.1 sunt variați, în timp ce restul sunt constanți. Apoi, pentru a obține un metamodel precis, propunerea noastră este de a antrena modele de învățare automată separate pentru fiecare regiune continuă din R_{on} .

Setul de date de simulare este compus din 500 de eșantioane prin care parametrii spațiului de proiectare acoperă regiunile de continue ale funcției R_{on} . Spațiul în care determinăm R_{on} este împărțit în două regiuni continue. Prin urmare, 100 de eșantioane acoperă o regiune redusă, iar restul de 400 acoperă cealaltă regiune. Pentru rețelele neurale, procentul de date utilizate pentru antrenare, validare și testare este același cu cel utilizat pentru *Tehnologia A* și validarea de tip *10 k-fold* pentru restul algoritmilor.

Au fost încercate două tipuri de abordări: (i) antrenarea unui singur metamodel (denumit *Single metamodel*) pentru întregul spațiu al parametrilor de proiectare, chiar dacă acesta are un hiperplan de discontinuitate, și (ii) antrenarea unor metamodele separate pentru fiecare regiune continuă, denumite *M1* pentru subspațiul mic și *M2* pentru subspațiul cel mai mare. Rezultatele antrenării metamodelelor sunt prezentate în tabelul 3.7 ca eroare relativă maximă exprimată în procente. Antrenarea unui singur metamodel pentru întregul spațiu al parametrilor nu manifestă rezultate bune.

Tabel 3.7 Evaluarea metamodelului *Technologiei B* folosind MRE[%] [NCB⁺23]

Algorithm	Single metamodel	Combined metamodel		
		M1	M2	Combined
Neural Networks	1.81	0.59	0.27	0.59
GPR Matern 5/2	2.40	0.50	0.42	0.50
GPR Rational Quadratic	2.91	0.70	0.60	0.70
SVM Cubic Regression	14.21	6.15	4.79	6.15
Linear Regression	82.03	41.23	25.41	41.23

3.5 Rezumat și concluzii

Acest capitol a prezentat o metodă de reducere a timpului de simulare a MOSFET-urilor de putere, urmată de o tehnică de învățare automată pentru a estima R_{on} pe baza rezultatelor simulării. În acest fel, ne atingem obiectivul principal de a reduce timpul total de simulare.

Metoda propusă pentru reglarea parametrilor care oferă o analiză este de mare importanță, în special în industrie, deoarece permite utilizatorului să aleagă parametrii care se potrivesc cel mai bine cerințelor. Introducerea tehnicilor de învățare automată pentru a estima R_{on} a unui MOSFET prezintă rezultate promițătoare. Metamodelele reprezintă alternative fiabile la abordările bazate exclusiv pe simulare și prezintă un avantaj semnificativ atunci când este obligatoriu un număr mare de simulări.

Capitolul 4

Aplicații ale metamodelor pentru MOSFET-uri de putere

4.1 Introducere

Scopul acestui capitol este de a demonstra importanța metamodelor prin intermediul unei serii de aplicații. O aplicație importantă este analiza sensibilității. O a doua aplicație se bazează pe posibilitatea de a utiliza metamodelele deja disponibile pentru a face procesul de ajustare și mai eficient. Cu toate acestea, cea mai avansată aplicație se referă la estimarea randamentului, un aspect de mare importanță pentru dispozitive.

4.2 Analiza sensibilității

O aplicație imediată a metamodelor este analiza sensibilității. Aceasta este una dintre sarcinile care necesită un număr mare de simulări. În acest fel, demonstrăm în mod eficient beneficiile metamodelor. Dimensiunea cipului și dimensiunea clipului sunt, prin definiție, cei mai importanți doi factori de influență pentru R_{on} . Prin urmare, analiza este efectuată pe restul parametrilor prezentați în tabelul 3.1. Se efectuează o analiză de sensibilitate utilizând 10 000 de eșantioane din spațiul valid al parametrilor de proiectare.

Pentru corelație, o valoare apropiată de 0 reprezintă cea mai mică influență, în timp ce o valoare apropiată de 1 sau -1 reprezintă o influență ridicată. Pentru restul metodelor, o valoare mai mare indică o influență mai mare. Tabelul 4.1 ilustrează rezultatele analizei de sensibilitate. Se poate observa că siliciul și grosimea clip-urilor sunt, în general, cele mai influente. Cu toate acestea, scopul este de a ilustra faptul că timpul redus de inferență permite acest tip de analiză. În comparație cu o singură simulare a R_{on} realizată cu ajutorul instrumentelor comerciale standard, timpul de inferență este de milioane de ori mai mic, având în vedere același hardware de calcul. Pe nodul de calcul utilizat de noi, simularea R_{on} durează peste 10 minute, în timp ce o singură inferență durează $100\mu s$. Timpul de inferență a fost calculat ca medie pe 10 000 de inferențe.

Tabel 4.1 Analiza sensibilității parametrilor de proiectare

Parametru	Metoda					
	Correlation	Entropy Pair	Entropy Simple	Brownian Distance	EFAST	Jansen
Silicon Thickness	0.29	1.00	0.08	0.02	0.00	1.11
Clip Thickness	-0.79	1.00	1.00	0.79	0.09	0.11
Top Metal 1 Thickness	-0.17	0.36	0.04	0.02	0.01	0.01
Top Metal 2 Thickness	-0.02	0.01	0.00	0.03	0.01	0.01
Top Solder Thickness	0.19	0.50	0.05	0.02	0.04	0.03
Bottom Solder Thickness	-0.01	0.00	0.00	0.02	0.00	0.00

4.3 Analiza proiectării experimentelor

În acest experiment, lungimea și lățimea cipului sunt variate, în timp ce restul parametrilor de proiectare sunt fixați la o valoare arbitrară. În acest fel, ilustrăm în Fig. 4.1 spațiul valid parametrilor de proiectare în cazul curent.

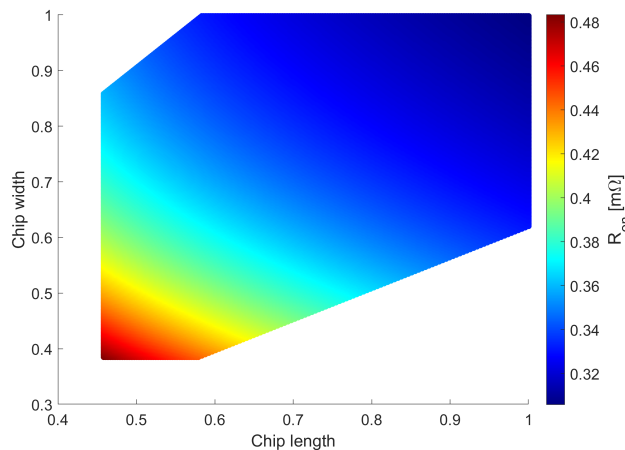


Figura 4.1 Spațiul valid al parametrilor de proiectare în cazul curent
Dimensiunile sunt normate la $[0, 1]$

În continuare, folosim acest set de date generat artificial pentru o investigație privind tehnicile de proiectare a experimentelor. În capitolul anterior, am prezentat abordarea noastră pentru proiectarea setului de date utilizat pentru antrenarea metamodelului. Primul pas în proiectarea setului de date este determinarea colțurilor spațiului parametrilor de proiectare. Propunem două metode pentru a decide coordonatele următoarelor eșantioane care vor fi incluse în setul de date. *HS* – eșantionul următor este poziționat

la coordonatele maximei erori absolute. În acest fel, estimăm că fiecare eşantion nou va aduce o contribuție semnificativă la performanța de predicție a metamodelului. *RS* – eşantionare aleatoare.

Pentru a arăta distribuția erorii în spațiul parametrilor de proiectare valabili, detaliem în continuare evoluția erorii de la 8 până la 11 eşantioane în Fig. 4.4. Graficele plasate în partea stângă ilustrează eroarea pentru eşantionarea *HS*, în timp ce în partea dreaptă sunt diagramele *RS1*.

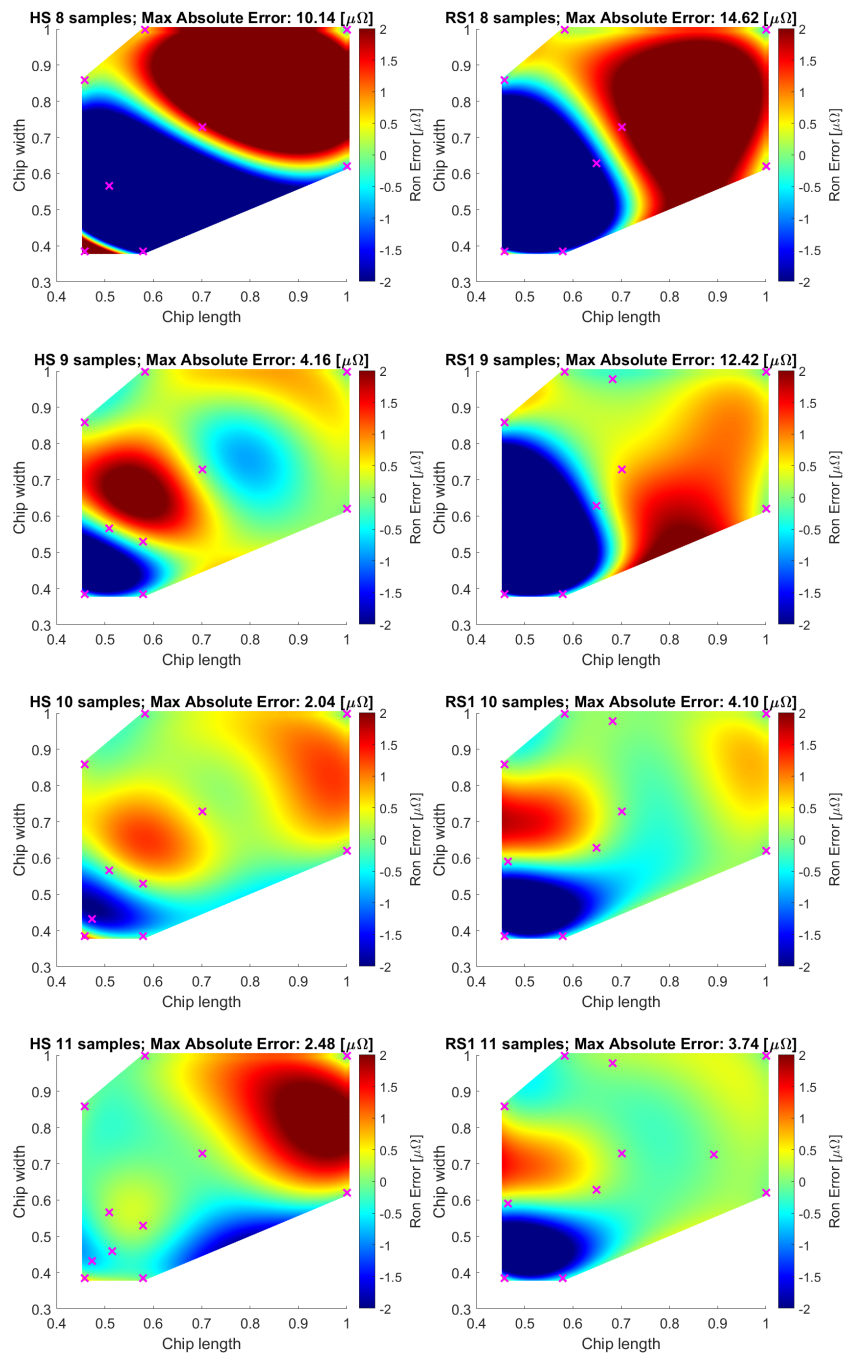


Figura 4.4 HS vs RS1 – de la 7 la 11 eşantioane
Dimensiunile sunt normate la $[0, 1]$

4.4 Îmbunătățirea randamentului parametric din producție

O subcategorie a randamentului, randament parametric, se referă la dispozitivele funcționale care nu îndeplinesc standardele de performanță necesare. Variațiile unuia sau mai multor parametri de proiectare în timpul procesului de producție reprezintă cauza principală a defecte. Prin urmare, distribuția variației parametrilor este esențială, deoarece poate indica faptul că anumite dispozitive nu îndeplinesc cerințele.

4.4.1 Provocări ale estimării randamentului folosind metamodele

Există multe metode propuse de eșantionare și modelare a caracteristicilor și performanțelor circuitelor, precum și diferite tehnici de estimare a randamentului pentru circuitele analogice și cu semnal mixt. Acestea pot fi clasificate în trei tipuri principale de abordări: (1) straightforward Monte Carlo (MC) [GYH11, PP02]; (2) statistical MC-based [LLGP04, LZP08, LZW⁺12, FYZL14, GTZZ20]; (3) Non-MC [GR08, GLY⁺12, GR21];


4.4.2 Metoda propusă pentru estimarea randamentului parametric

Ipoteza pleacă de la faptul că un tip de dispozitiv este de regulă produs într-o singură fabrică. Prin urmare, după ce se proiectează un nou dispozitiv de același tip, acesta va fi trimis spre producție la fabrica respectivă. Setul de mașini de fabricație va fi același ca și în cazul dispozitivelor anterioare. Datele de fabricație ale acestor dispozitive sunt disponibile, iar noi ne propunem să prelucrăm aceste date și să le utilizăm pentru a estima variația parametrilor unui dispozitiv nou proiectat. Metoda constă în două blocuri funcționale: Blocul A: Modelarea variațiilor în fabricație și Blocul B: Modelarea tehnologiei.


4.4.3 Scenariu experimental

Figura 4.9a prezintă o estimare a dispersiei lui R_{on} pe parcursul procesului de fabricație pentru un MOSFET obținut cu ajutorul tehnicii de optimizare automată propuse. Putem observa un număr de dispozitive, plasate în zona roșie, care nu îndeplinesc cerința da R_{on} impusă. Curba roșie a funcției de densitate de probabilitate ilustrează o estimare a modului în care R_{on} va fi influențat de procesul de fabricație a acestui nou dispozitiv. Linia roșie verticală, *Upper Spec limit*, reprezintă valoarea impusă a lui R_{on} . În cazul în care acest proiect de MOSFET trece în faza de producție, aproximativ 20% din dispozitivele fabricate nu vor îndeplini performanța cerută, iar componenta de randament asociată defectelor parametrică va fi de aproximativ 80,66%.

Metoda propusă reprezintă un instrument de asistență la proiectare pentru determinarea celui mai bun randament parametric fără a sacrifica costul sau performanța. Din acest punct de vedere, fiabilitatea proiectării optime este strâns corelată cu parametrii



(a) Randament – structura inițială: 80.66%



(b) Randamentul – structura optimizată: 99.82%

Figura 4.9 Estimarea distribuției R_{on} în procesul de fabricație [NBC⁺22]

de proiectare și cu gradul de precizie al caracterizării acestora. După cum se arată în Fig. 4.9, schimbarea distribuției parametrilor de proiectare duce la o creștere cu 19% a randamentului parametric. Principalul avantaj al tehnicii propuse constă în proiectarea de produse cu performanțe îmbunătățite la costuri de fabricație reduse în fiecare caz.

4.5 Rezumat și concluzii

Prima aplicație importantă este analiza sensibilității. Pentru aceasta, am efectuat un număr de 10.000 de inferențe și am determinat un timp mediu al procesorului de $100\mu s$ pentru o singură predicție a lui R_{on} , comparativ cu 10 minute folosind simularea convențională pe același hardware.

O a doua aplicație propusă a fost o analiză de proiectare a experimentelor. Pentru a investiga importanța poziției eșantioanelor, am efectuat mai multe experimente, folosind peste 50 000 de inferențe. Rezultatele au indicat pozițiile celor mai importante eșantioane, pe care le putem include în continuare în setul de date pentru următoarele metamodele.

În cele din urmă, am propus o metodă de îmbunătățire a randamentului parametric prin estimarea acestui randament în pre-siliciu. Aceasta se bazează pe modelarea datelor de fabricație folosind o distribuție multivariată în prima etapă. Apoi, randamentul este estimat folosind metamodele pentru a prezice valorile de R_{on} aferente eșantioanelor generate din distribuția multivariată.

Capitolul 5

Proiectarea rentabilă a MOSFET-urilor de putere

5.1 Introducere

Acest capitol se concentrează pe optimizarea automată a proiectării MOSFET-urilor de putere în ceea ce privește specificațiile de performanță ale acestora. Metodele propuse realizează o proiectare care ține cont de costuri.

5.2 Metoda propusă de optimizare a proiectării

Durata procesului de proiectare trebuie să fie îmbunătățită pentru a răspunde cererii ridicate de dispozitive specifice pentru aplicații. Impactul reducerii timpului de proiectare este ridicat, deoarece permite producerea de dispozitive optime în ceea ce privește cerințele lor pentru aplicații specifice. Este necesar să se determine un set optim de parametri de proiectare pentru a proiecta dispozitive de înaltă performanță, economisind în același timp suprafața de siliciu. Decizia de a stabili dacă un proiect de MOSFET îndeplinește specificațiile este luată de inginerii de proiectare. Deși acest proces asigură performanța dispozitivului MOSFET, el nu garantează suprafața minimă de siliciu. Având în vedere acest lucru, metoda propusă include un algoritm de optimizare capabil să asigure atât îndeplinirea cerințelor, cât și minimizarea ariei.

5.2.1 Prezentare generală

Reprezentarea schematică a metodei propuse este prezentată în figura 5.2. Aplicația din industrie a metodei propuse constă în dezvoltarea unui instrument de asistență pentru proiectarea MOSFET-urilor. Acest instrument este menit să crească eficiența procesului de proiectare și să scutească experții de o muncă manuală repetitivă.

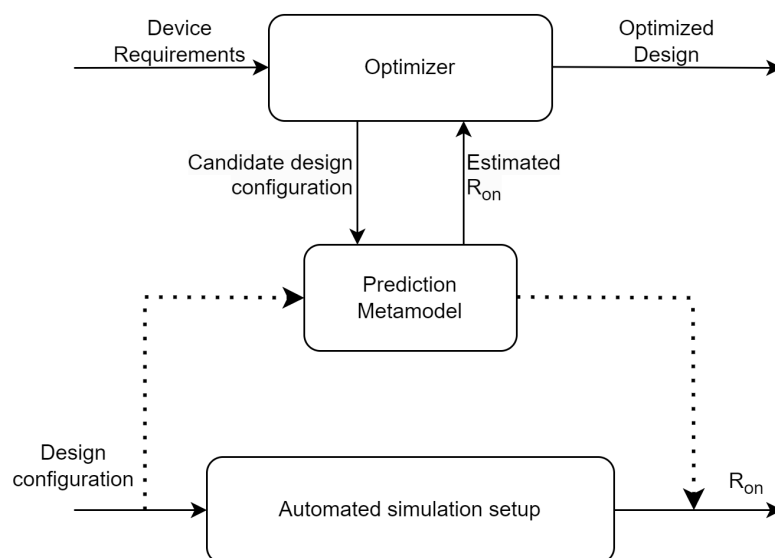


Figura 5.2 Schema bloc a optimizării automate a proiectării [NCB⁺23]

5.2.2 Considerații asupra folosirii metamodelelor în optimizarea automată proiectării

Un exemplu practic este prezentat în Fig. 5.3. Această diagramă ilustrează o secțiune a spațiului parametrilor constând din două variabile: lungimea și lățimea cipului. Restul parametrilor de proiectare sunt fixați la o valoare arbitrară. Eșantioanele au fost evaluate utilizând metamodelul R_{on} pentru *Tehnologia A*, descris în capitolul anterior. Suprafața delimitată cu verde corespunde combinațiilor valide de lungime și lățime ale cipului. Constrângerile de proiectare nu sunt respectate dincolo aceasta. În aceste regiuni există cel puțin o încălcare a regulilor de proiectare, prin urmare, configurațiile parametrilor de proiectare din aceste zone reprezintă dispozitive care nu pot fi fabricate.




Figura 5.3 Secțiune a spațiului parametrilor. Dimensiunile sunt normate în intervalul [0,1]

5.2.3 Formularea problemei de optimizare

Determinarea compromisului optim între cost și performanță în proiectarea unui dispozitiv MOSFET implică identificarea celor trei componente ale unei probleme de optimizare: variabile, constrângeri și funcția obiectiv.

Variabile

- 1) $ChipLength$, 2) $ChipWidth$, 3) $ClipLength$, 4) $ClipWidth$

Constrângeri

- (a) Lungimea minimă a cipului $\leq ChipLength \leq$ Lungimea maximă a cipului
- (b) Lățimea minimă a cipului $\leq ChipWidth \leq$ Lățimea maximă a cipului
- (c) Lungimea minimă a clipului $\leq ClipLength \leq$ Lungimea maximă a clipului
- (d) Lățimea minimă a clipului $\leq ClipWidth \leq$ Lățimea maximă a clipului
- (e) Formatul minim al cipului $\leq \frac{ChipWidth}{ChipLength} \leq$ Formatul maxim al cipului
- (f) Formatul minim al clipului $\leq \frac{ClipWidth}{ClipLength} \leq$ Formatul maxim al clipului
- (g) $\frac{ChipLength - ClipLength}{2} \geq \delta_{length}$
- (h) $\frac{ChipWidth - ClipWidth}{2} \geq \delta_{width}$
- (i) $R_{on} \leq R_{on_specification}$

unde: δ_{length} reprezintă distanța minimă dintre marginea cipului și marginea clipului pe partea mai lungă, iar δ_{width} reprezintă distanța minimă dintre marginea cipului și marginea clipului pe partea mai scurtă.

Funcția obiectiv

$$\bullet F(X) = ChipLength \times ChipWidth$$

cu $X = \left(ChipLength \quad ChipWidth \quad ClipLength \quad ClipWidth \right)^T$, vectorul de variabile.

Cu variabilele, constrângerile și funcția obiectiv definite, compromisului între cost și performanță (R_{on}) pentru un dispozitiv MOSFET este definit în cele ce urmează.

Minimizează $F(X)$

respectând:

- constrângerile liniare (a) – (h);
- constrângerea neliniară i);

(5.1)

5.2.4 Optimizarea proiectării pentru o funcție R_{on} continuă

În cazul de față, formularea problemei este adaptată pentru a se potrivi la optimizarea proiectării MOSFET-urilor de putere. Aceasta este una dintre principalele noastre contribuții și este prezentată mai jos.

$$\text{Minimizează } F(X) \text{ astfel încât } \begin{cases} c(X) \leq 0 \\ A \cdot X \leq b \\ lb \leq x \leq ub \end{cases} \quad (5.3)$$

unde:

- $c(X) = R(X) - R_{on_specification}$; (constrângerea (i))
- lb & ub sunt limitele variabilelor; (constrângerile (a) – (d))
- $F(X)$ este funcția obiectiv

Constrângerile (e) și (f) sunt definite în (5.4) folosind inegalitatea de mijloc din (5.3).

$$\begin{pmatrix} ChAR_{min} & -1 & 0 & 0 \\ -ChAR_{max} & 1 & 0 & 0 \\ 0 & 0 & CIAR_{min} & -1 \\ 0 & 0 & -CIAR_{max} & 1 \end{pmatrix} \times \begin{pmatrix} ChipLength \\ ChipWidth \\ ClipLength \\ ClipWidth \end{pmatrix} \leq \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \end{pmatrix} \quad (5.4)$$

unde:

- $ChAR_{min}$ & $ChAR_{max}$ sunt limitele factorului de aspect pentru cip
- $CIAR_{min}$ & $CIAR_{max}$ sunt limitele factorului de aspect pentru clip
- factorul de aspect este definit ca $\frac{width}{length}$

Constrângerile (g) și (h) sunt definite în (5.5) folosind inegalitatea de mijloc din (5.3).

$$\begin{pmatrix} 1 & 0 & -1 & 0 \\ 0 & 1 & 0 & -1 \end{pmatrix} \times \begin{pmatrix} ChipLength \\ ChipWidth \\ ClipLength \\ ClipWidth \end{pmatrix} \leq \begin{pmatrix} 2\delta_{length} \\ 2\delta_{width} \end{pmatrix} \quad (5.5)$$

În cele din urmă, inegalitatea de mijloc din (5.3) este exprimată ca (5.6).

$$\begin{pmatrix} ChAR_{min} & -1 & 0 & 0 \\ -ChAR_{max} & 1 & 0 & 0 \\ 0 & 0 & CIAR_{min} & -1 \\ 0 & 0 & -CIAR_{max} & 1 \\ 1 & 0 & -1 & 0 \\ 0 & 1 & 0 & -1 \end{pmatrix} \times \begin{pmatrix} ChipLength \\ ChipWidth \\ ClipLength \\ ClipWidth \end{pmatrix} \leq \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 2\delta_{length} \\ 2\delta_{width} \end{pmatrix} \quad (5.6)$$

5.2.5 Abordarea discontinuităților

O discontinuitate are un mare impact în optimizare, deoarece creează un hiperplan tridimensional de discontinuitate în domeniul funcției R_{on} . Prin urmare, optimizatorul trebuie să fie robust la acest tip de discontinuitate. Pentru a depăși această problemă, propunem utilizarea lui *differential evolution*, un algoritm de optimizare meta-euristică.

Formularea problemei pentru optimizatorul de tip *differential evolution* este ilustrată în (5.7).

$$\text{Minimize } f(X) \text{ such that } lb \leq X \leq ub \quad (5.7)$$

unde lb & ub sunt valorile limită ale parametrilor de proiectare (constrângerile (a) – (d)) și $f(X)$ este funcția obiectiv .

Din (5.7) observăm că *differential evolution* nu oferă mecanisme pentru alte tipuri de constrângeri. Pentru a depăși acest aspect, abordarea propusă constă în ajustarea funcției obiectiv pentru a include constrângerile (e) – (i). Prin urmare, definim funcția obiectiv ca o sumă de 3 factori, așa cum este ilustrat în (5.8). Exprimarea sub forma unei sume, putem controla mai ușor caracteristicile matematice ale funcției obiectiv.

$$F_{DE}(X) = F(X) + F_{cost_DR}(X) + F_{cost_Ron}(X) \quad (5.8)$$

unde $F(X)$ reprezintă suprafața cipului conform (5.3); $F_{cost_DR}(X)$ reprezintă constrângerile (e) – (h) conform (5.9) și $F_{cost_Ron}(X)$ reprezintă constrângerile (i) conform (5.10).

Primul termen, $F(X)$, a fost deja prezentat în subsecțiunea anterioară. $F_{cost_DR}(X)$ și $F_{cost_Ron}(X)$ sunt concepute pentru a adăuga o penalizare la $F_{DE}(X)$ în cazul în care constrângerile nu sunt respectate sau acordând o bonificare dacă se respectă spațiul valid al parametrilor de proiectare.

$$F_{cost_DR}(X) = \begin{cases} -DR_{Scale} & ,\text{if } \Delta_{DR}(X) \leq 0 \\ DR_{Scale} \cdot \Delta_{DR}(X) & ,\text{if } \Delta_{DR}(X) > 0 \end{cases} \quad (5.9)$$

unde $\Delta_{DR}(X)$ este o metrică cumulativă a încălcărilor regulilor de proiectare, DR_{Scale} este un coeficient de scalare pentru $\Delta_{DR}(X)$.

$$F_{cost_Ron}(X) = \begin{cases} -R_{on_Scale} & ,\text{if } \Delta_{Ron}(X) \leq 0 \\ R_{on_Scale} \cdot \Delta_{Ron}(X) & ,\text{if } \Delta_{Ron}(X) > 0 \end{cases} \quad (5.10)$$

unde $\Delta_{Ron}(X) = R(X) - R_{on_specificație}$, R_{on_Scale} este un coeficient de scalare pentru $\Delta_{Ron}(X)$.

5.2.6 Validarea structurii optime

Propunem o procedură de validare a soluției optime structurată în două etape, după cum urmează. Prima etapă urmărește să demonstreze că soluția optimă nu depinde de punctul de plecare al algoritmilor de optimizare. A doua etapă constă în compararea

soluției rezultate în urma metodei de optimizare automată cu soluțiile optime obținute de proiectanți cu ajutorul metodologiei standard.

5.3 Rezultate experimentale

Pentru optimizarea automată a proiectării dispozitivelor, există două cazuri de utilizare, fiecare dintre ele având o tehnologie specifică de tranzistori. *Tehnologia A* utilizează un set de tehnici de proiectare standard constând în redimensionarea straturilor; prin urmare, funcția R_{on} este continuă. *Tehnologia B* se caracterizează prin elemente geometrice discrete în proiectare, care depind de dimensiunea tranzistorului.

5.3.1 Studiu de caz 1: Optimizare pentru *Tehnologia A*

În cazul de față, R_{on} este estimat folosind metamodelul de învățare automată al *Tehnologiei A*. Pentru optimizare se poate utiliza un algoritm de optimizare determinist. Fig. 5.9 ilustrează faptul că, indiferent de punctul de plecare, structura optimă determinată de algoritm este același.




Figura 5.9 Optimizarea suprafeței cipului pentru *Tehnologia A* începând de la trei configurații de proiectare [NCB⁺23]. Aria cipului este normalată la intervalul [0,1]

5.3.2 Studiu de caz 2: Optimizare pentru *Tehnologia B*

Fig. 5.11 ilustrează discontinuitatea metamodelului pentru *Tehnologia B*. Creșterea dimensiunii cipului, dincolo de un anumit prag, are ca rezultat schimbări discrete în structura dispozitivului. În *Tehnologia B*, numărul de *gate fingers* depinde de dimensiunea cipului pentru a obține o performanță mai mare a dispozitivului. Pentru a ilustra aceste schimbări discrete, lungimea cipului și dimensiunile clipurilor au fost fixate la valori arbitrare, în timp ce lățimea cipului a fost variată în intervalul valid. R_{on} a fost estimat folosind metamodelul *Tehnologiei B*. Discontinuitatea este definită în (5.12).

$$\lim_{ChW \rightarrow Th^-} R(X) \neq \lim_{ChW \rightarrow Th^+} R(X) \quad (5.12)$$

$$\lim_{ChW \rightarrow Th^-} R(X) = R(X_{Th})$$

unde $R(X)$ este funcția de estimare R_{on} ; ChW este lățimea cipului lui X ; Th este valoarea de prag a lățimii cipului; $X_{Th} = \left(ChipLength \ Th \ ClipLength \ ClipWidth \right)^T$.

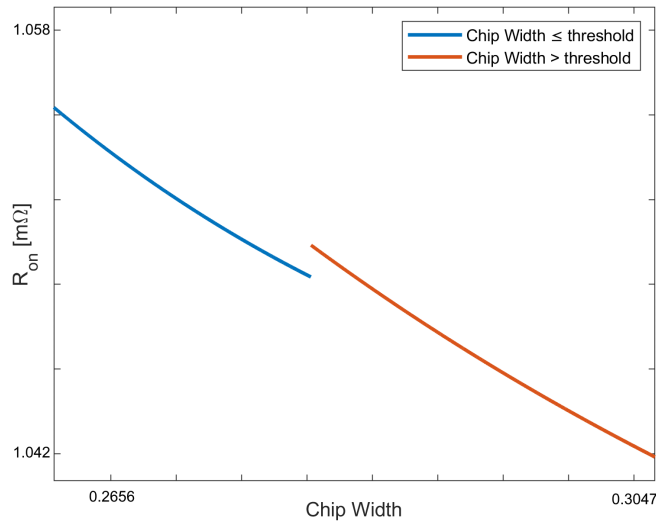


Figura 5.11 Punct de discontinuitate în funcția R_{on} . Dimensiunile sunt normate la intervalul $[0,1]$

Cu F_{cost_DR} și F_{cost_Ron} proiectate, următorul pas este determinarea funcției obiectiv F_{DE} ca în (5.8). Fig. 5.19 ilustrează un exemplu de F , F_{cost_DR} și F_{cost_Ron} împreună cu influența lor asupra F_{DE} . Pentru o mai bună reprezentare, fiecare grafic este format din 100,000 de eșantioane distribuite uniform în spațiul parametrilor de proiectare. Dimensiunile clipurilor sunt fixate la o valoare arbitrară, iar intervalul dimensiunilor clipurilor este același în toate cele patru diagrame. Scopul este de a ilustra un exemplu de modul în care funcția obiectiv F_{DE} proiectată conduce la obținerea optimului. Cele patru diagrame din Fig. 5.19 sunt următoarele: (1) reprezintă funcția F , primul termen al lui F_{DE} , suprafața cipului; (2) reprezintă funcția F_{cost_DR} , al doilea termen al lui F_{DE} , costul încălzirii regulilor de proiectare; (3) reprezintă funcția F_{cost_Ron} , al treilea termen al lui F_{DE} , costul R_{on} ; (4) reprezintă funcția obiectiv $F_{DE} = F + F_{cost_DR} + F_{cost_Ron}$.

Pentru o validare statistică, figura 5.21 prezintă rezultatele optimizării de tip *differential evolution* și le compară cu cele ale algoritmului de tip *interior-point*. Deoarece funcția de R_{on} nu este continuă, utilizarea optimizatorului *interior-point* nu determină optimul pentru toate punctele de plecare. Pentru generarea acestui grafic, 1.000 de eșantioane uniforme din spațiul de proiectare sunt utilizate ca puncte de plecare pentru optimizare. Punctele portocalii ilustrează valorile optime identificate de optimizatorul *interior-point*. După cum era de așteptat, discontinuitatea nu este gestionată corespunzător.




Figura 5.19 Exemplu pentru funcția obiectiv și componentele sale. Dimensiunile sunt normate la $[0,1]$

tor. Pentru o comparație numerică, cele mai eronate soluții sunt luate în considerare atât pentru *differential evolution*, cât și pentru *interior-point*. În acest caz specific, suprafața cipului este cu 3,11% mai mare pentru rezultatele obținute de optimizatorul *interior-point* în comparație cu *differential evolution*.

Evaluarea dispozitivelor fizice rezultate în urma metodei de optimizare urmează să fie efectuată, deoarece fabricarea unui nou dispozitiv implică multe alte aspecte în ceea ce privește producția. Prin urmare, evaluarea acestor modele optime a fost realizată de către experții în inginerie de proiectare doar la nivel de simulare. Cu toate acestea, la evaluarea dispozitivelor rezultate în urma optimizării automate a proiectării au fost utilizate măsurători anterioare ale produselor reale și date de simulare. Deși experții în proiectare au confirmat îmbunătățirile metodei, o mențiune specială este aceea că această evaluare este confidențială și, prin urmare, nu poate fi divulgată.




Figura 5.21 Optimizarea suprafeței cipului pentru *Tehnologia B* [NCB⁺23]. Aria cipului este normată la [0,1]

5.4 Rezumat și concluzii

Acest capitol a prezentat o tehnică de optimizare automată a proiectării pentru MOSFET-urile de putere. În acest fel, abordarea se concentrează pe compromisul dintre cost și performanță.

Am propus o metodă formată din trei blocuri pentru a realiza optimizarea automată a proiectării: un mediu de automatizare a simulărilor, un metamodel de predicție și un optimizator de proiectare. În capitolul precedent, pentru primele două au fost descrise provocările tehnice și strategiile de depășire a acestora. Prin urmare, accentul din acest capitol a fost orientat spre blocul rămas. Etapele preliminare către optimizare constau în definirea variabilelor de proiectare, a regulilor de proiectare, a constrângerilor R_{on} și a funcției obiectiv. În primul rând, a fost prezentată optimizarea proiectării cu o funcție R_{on} continuă. Apoi, s-a acordat o atenție deosebită discontinuităților funcției de estimare R_{on} și provocărilor ridicate de acestea. Structurile optime sunt confirmate printr-o evaluare statistică. Diferențele ne semnificative, mai mici de 10^{-5} , ale R_{on} și ale suprafeței cipului în raport cu punctul de plecare sunt cauzate de zgomotul numeric.

Capitolul 6

Concluzii generale

Această cercetare are ca scop îmbunătățirea metodologiei de proiectare pentru viitoarele dispozitive MOSFET de putere. Metodele manuale actuale au fost îmbunătățite pentru a satisface cerințele mai ridicate pentru aplicațiile de putere. Toate aceste îmbunătățiri se bazează pe tehnici de învățare automată.

6.1 Obiective și rezultate

Există două obiective majore care contribuie la prezenta metodologie de proiectare pentru noile MOSFET-uri de putere. Fiecare este legat de o componentă critică a procesului de proiectare. Acestea sunt prezentate în cele ce urmează.

O1. Accelerarea tehnicilor de analiză a simulării MOSFET-urilor de putere

Timpul necesar pentru analiză este un factor important pentru performanța finală a dispozitivului. Pentru realizarea acestui obiectiv există trei obiective specifice.

O1.1. Reducerea timpului de configurare a simulării

Rezultatul acestui obiectiv este o metodă automată pentru reglarea parametrilor în simularea cu elemente finite a MOSFET-urilor de putere. Această tehnică este prezentată în capitolul 3, secțiunea 3.2.2.

O1.2. Reducerea timpului pentru analiza bazată pe simulare

Acest obiectiv este realizat prin dezvoltarea unui mediu de simulare automată. Rezultatele simulării pentru un set de experimente definite sunt obținute automat cu ajutorul acestui proces. Mai multe detalii au fost ilustrate în capitolul 3, secțiunea 3.2.3.

O1.3. Reducerea numărului de simulări în sarcinile dificile

Acest lucru se realizează prin adaptarea metamodelor de predicție pe baza rezultatelor simulării. Pentru antrenarea și evaluarea metamodelor este necesar un număr limitat de simulări. Acest lucru a fost detaliat în capitolul 3, secțiunea 3.3.

O2. Asigurarea rentabilității și fiabilității în proiectarea MOSFET-urilor de putere

Fabricarea dispozitivelor de înaltă performanță la cel mai mic cost necesită o proiectare optimă în ceea ce privește atât pierderea de material, cât și randamentul în fabricație.

O2.1. Definirea problemei de optimizare automată

Rezultatul acestui obiectiv este o formulare matematică a optimizării dispozitivelor. Aceasta a fost prezentată în capitolul 4, secțiunea 5.2.3.

O2.2. Dezvoltarea aplicației de optimizare automată.

A fost dezvoltat un cadru de optimizare automată luând în considerare aspectele practice în ceea ce privește tehnologiile de tranzistori. Secțiunile 5.2.4 și 5.2.5 din capitolul 4 includ pașii importanți pentru realizarea acestui obiectiv.

O2.3. Îmbunătățirea randamentului parametric în fabricație

Fiabilitatea proiectului în producție este asigurată prin utilizarea unei metode de estimare inițială a randamentului parametric pe baza datelor de fabricație anterioare. Această metodă a fost prezentată în capitolul 4, secțiunea 4.4.2.

6.2 Contribuții originale

Principalele contribuții privind metodologia de analiză a MOSFET-urilor de putere, prezentate în capitolul 3, sunt următoarele:

- O metodă de accelerare a reglării parametrilor în simularea cu elemente finite. Aceasta are rolul de a-i ajuta pe ingineri să reducă riscul de a obține rezultate eronate ale simulării și de a găsi un bun compromis între timpul de simulare și acuratețe. Astfel, contribuie la reducerea timpului total de simulare [NBB⁺20].
- O metodă de antrenare a metamodelor pentru R_{on} . Cu un set inițial de simulări cu elemente finite pentru obținerea setului de date, metamodelele sunt capabile de estimare a parametrului R_{on} . Dimensiunea setului de date, care este necesară pentru ca această tehnică să funcționeze corect, depinde nu numai de numărul de parametri de intrare, ci și de modul în care acești parametri influențează rezultatul final [NBF⁺21].
- O metodă de tratare a discontinuităților în antrenarea metamodelor pentru R_{on} . Aceasta este o extensie a metodei anterioare, care asigură o precizie ridicată la modelarea tehnologiilor complexe [NCB⁺23].

Principalele contribuții în ceea ce privește aplicațiile metamodelului MOSFET-urilor de putere, prezentate în capitolul 4, sunt următoarele:

- Un studiu privind cei mai influenți parametri de proiectare ai MOSFET-ului de putere, cu accent pe cerințele pentru realizarea acestui tip de analiză de sensibilitate.

- Un studiu care compară două metode de proiectare a experimentelor pentru setul de date de antrenare, demonstrând că folosirea cunoștințelor anterioare pentru eșantionare are un impact semnificativ asupra performanței finale a metamodelului.
- O metodă de îmbunătățire a randamentului în fabricație printr-o estimare parametrică inițială a randamentului în pre-siliciu. Această metodă utilizează datele de producție disponibile pentru a modela variația parametrilor în producție. Apoi, folosind metamodele, se obține o distribuție a randamentului în fabricație [NBC⁺22].

Principalele contribuții în ceea ce privește tehnicile de proiectare a MOSFET-urilor de putere, prezentate în capitolul 5, sunt următoarele:

- O metodă de optimizare a proiectării pentru MOSFET-uri de putere bazată pe algoritmi determinați [NCB⁺23]. Aceasta utilizează metamodelele de învățare automată în locul simulării cu elemente finite pentru a accelera procesul de optimizare. Optimizarea deterministă este adecvată pentru a ajunge la o proiectare optimă în tehnologiile de tranzistor simple. Rezultatele au demonstrat performanțe ridicate în determinarea suprafeței minime a cipului pentru un R_{on} impus.
- O metodă de optimizare a proiectării pentru MOSFET-uri de putere bazată pe algoritmi metaeuristici [NCB⁺23]. Asigurând o configurare adecvată a metodei de optimizare, optimul poate fi determinat în orice condiții.

6.3 Lista de lucrări originale

1. [NBB⁺20] G. Nicolae, C. Boianeanu, A. Buzo, C.V. Diaconu, H. Cucu, G. Pelz, and C. Burileanu. Automatic parameter tuning in finite element analysis of semiconductor packages. In *2020 International Semiconductor Conference (CAS)*, pages 41–44, Virtual Conference, 2020, ISI WOS:000637264600009
2. [NBF⁺21] G. Nicolae, A. Buzo, C. Feuerbaum, C.V. Diaconu, H. Cucu, G. Pelz, and C. Burileanu. Metamodel-based prediction of on resistance for microelectronic power switches. In *2021 IEEE Electrical Design of Advanced Packaging and Systems (EDAPS)*, pages 1–3, Virtual Conference, 2021, ISI WOS:000927194000010
3. [NBC⁺22] G. Nicolae, A. Buzo, H. Cucu, C. Burileanu, and G. Pelz. Manufacturing variation estimation of on resistance in power semiconductors. In *2022 18th International Conference on Synthesis, Modeling, Analysis and Simulation Methods and Applications to Circuit Design (SMACD)*, pages 1–4, Villasimius, Sardinia, Italy, 2022
4. [NCB⁺23] G. Nicolae, H. Cucu, C. Burileanu, A. Buzo, C. Feuerbaum, and G. Pelz. Automatic design optimization of microelectronic power switches. *UNIVERSITY POLITEHNICA OF BUCHAREST SCIENTIFIC BULLETIN SERIES*

C-ELECTRICAL ENGINEERING AND COMPUTER SCIENCE, 85(1):377–388, 2023, ISI WOS:000957721700001

5. [GND⁺20] Andrei Gaita, Georgian Nicolae, Emilian C. David, Andi Buzo, Corneliu Burileanu, and Georg Pelz. A SIFT-based Waveform Clustering Method for aiding analog/mixed-signal IC Verification. In *2020 IEEE EUROPEAN TEST SYMPOSIUM (ETS 2020)*, Proceedings of the European Test Symposium, Virtual Conference, 2020. 25th IEEE European Test Symposium (ETS), ELECTRONETWORK, MAY 25-29, 2020, ISI WOS:000615974000037

6.4 Lista de rapoarte tehnice

1. [Nic19b] G. Nicolae. Optimization of power electronics packaging, fabrication process and device simulation. *Technical Report No. 1, University Politehnica of Bucharest*, June 2019
2. [Nic19b] G. Nicolae. A machine learning approach for mesh optimization in thermal analysis of semiconductor packages. *Technical Report No. 2, University Politehnica of Bucharest*, December 2019
3. [Nic20] G. Nicolae. Multi-objective optimization of electronic packages. *Technical Report No. 3, University Politehnica of Bucharest*, June 2020

6.5 Perspective de dezvoltare ulterioară

Îmbunătățirea metodei de reglare a parametrilor pentru simularea cu elemente finite pentru structuri MOSFET mai complexe și definirea unei metrici pentru determinarea combinației optime de parametri de simulare.

Reducerea dimensiunii setului de date de simulare pentru antrenarea metamodelor folosind date de la mai multe tehnologii. Tehnicile de ultimă oră de învățare prin transfer (*transfer learning*) pot reprezenta o soluție.

Îmbunătățirea metamodelor prin includerea mai multor factori de influență ai R_{on} pentru a acoperi situații mai complexe. Anumiți parametri tehnologici, care sunt acum fixați în simulare, reprezintă un bun exemplu.

Extinderea tehnicii propuse de metamodelare pentru estimarea mai multor parametri de performanță ai MOSFET-urilor de putere. De exemplu, Z_{thJC} și aria sigură de funcționare sunt indicatori importanți ai performanței tranzistorului.

Îmbunătățirea tehnicii de antrenare a metamodelor pentru o mai bună gestionare a schimbărilor categorice în proiectarea tranzistorului. O modalitate de a face acest lucru este de a utiliza tehnici de învățare automată de tip clasificare pentru a defini marginile spațiilor continue, în timp ce tehnicile de regresie estimează răspunsul în aceste spații.

Bibliografie

- [BIMR18] Giovanni Breglio, Andrea Irace, Luca Maresca, and Michele Riccio. Electro-thermal simulations of power semiconductor devices during high stress events. In *2018 IEEE International Conference on Electrical Systems for Aircraft, Railway, Ship Propulsion and Road Vehicles & International Transportation Electrification Conference (ESARS-ITEC)*, pages 1–4, 2018.
- [FYZL14] Chenlei Fang, Fan Yang, Xuan Zeng, and Xin Li. Bmf-bd: Bayesian model fusion on bernoulli distribution for efficient yield estimation of integrated circuits. In *2014 51st ACM/EDAC/IEEE Design Automation Conference (DAC)*, pages 1–6, 2014.
- [GLY⁺12] Fang Gong, Xuexin Liu, Hao Yu, Sheldon X. D. Tan, Junyan Ren, and Lei He. A fast non-monte-carlo yield analysis and optimization by stochastic orthogonal polynomials. *ACM Trans. Des. Autom. Electron. Syst.*, 17(1), jan 2012.
- [GND⁺20] Andrei Gaita, Georgian Nicolae, Emilian C. David, Andi Buzo, Corneliu Burileanu, and Georg Pelz. A SIFT-based Waveform Clustering Method for aiding analog/mixed-signal IC Verification. In *2020 IEEE EUROPEAN TEST SYMPOSIUM (ETS 2020)*, Proceedings of the European Test Symposium, Virtual Conference, 2020. 25th IEEE European Test Symposium (ETS), ELECTR NETWORK, MAY 25-29, 2020.
- [GR08] Chenjie Gu and Jaijeet Roychowdhury. An efficient, fully nonlinear, variability-aware non-monte-carlo yield estimation procedure with applications to sram cells and ring oscillators. In *2008 Asia and South Pacific Design Automation Conference*, pages 754–761, 2008.
- [GR21] Zhengqi Gao and Ron Rohrer. Efficient non-monte-carlo yield estimation. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, pages 1–1, 2021.
- [GTZZ20] Zhengqi Gao, Jun Tao, Dian Zhou, and Xuan Zeng. Efficient parametric yield estimation over multiple process corners via bayesian inference based on bernoulli distribution. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 39(10):3144–3148, 2020.
- [GYH11] Fang Gong, Hao Yu, and Lei He. Stochastic analog circuit behavior modeling by point estimation method. In *Proceedings of the 2011 International Symposium on Physical Design, ISPD '11*, page 175–182, New York, NY, USA, 2011. Association for Computing Machinery.
- [HHL21] Chen He, Hanbin Hu, and Peng Li. Applications for machine learning in semiconductor manufacturing and test (invited paper). In *2021 5th IEEE Electron Devices Technology & Manufacturing Conference (EDTM)*, pages 1–3, 2021.

- [Hoo12] Holger H. Hoos. Automated algorithm configuration and parameter tuning. In Youssef Hamadi, Eric Monfroy, and Frédéric Saubion, editors, *Autonomous Search*, pages 37–71. Springer Berlin Heidelberg, Berlin, Heidelberg, 2012.
- [HP05] P.L. Hower and S. Pendharkar. Short and long-term safe operating area considerations in Idmos transistors. In *2005 IEEE International Reliability Physics Symposium, 2005. Proceedings. 43rd Annual.*, pages 545–550, 2005.
- [ICFQ93] K.B. Irani, J. Cheng, U.M. Fayyad, and Z. Qian. Applying machine learning to semiconductor manufacturing. *IEEE Expert*, 8(1):41–47, 1993.
- [LLGP04] Xin Li, Jiayong Le, P. Gopalakrishnan, and L.T. Pileggi. Asymptotic probability extraction for non-normal distributions of circuit performance. In *IEEE/ACM International Conference on Computer Aided Design, 2004. ICCAD-2004.*, pages 2–9, 2004.
- [LZP08] Xin Li, Yaping Zhan, and Lawrence T. Pileggi. Quadratic statistical *max* approximation for parametric yield estimation of analog/rf integrated circuits. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 27(5):831–843, 2008.
- [LZW⁺12] Xin Li, Wangyang Zhang, Fa Wang, Shupeng Sun, and Chenjie Gu. Efficient parametric yield estimation of analog/mixed-signal circuits via bayesian model fusion. In *2012 IEEE/ACM International Conference on Computer-Aided Design (ICCAD)*, pages 627–634, 2012.
- [Mur12] Kevin P Murphy. *Machine learning: a probabilistic perspective*. Cambridge, MA, 2012.
- [NBB⁺20] G. Nicolae, C. Boianceanu, A. Buzo, C.V. Diaconu, H. Cucu, G. Pelz, and C. Burileanu. Automatic parameter tuning in finite element analysis of semiconductor packages. In *2020 International Semiconductor Conference (CAS)*, pages 41–44, Virtual Conference, 2020.
- [NBC⁺22] G. Nicolae, A. Buzo, H. Cucu, C. Burileanu, and G. Pelz. Manufacturing variation estimation of on resistance in power semiconductors. In *2022 18th International Conference on Synthesis, Modeling, Analysis and Simulation Methods and Applications to Circuit Design (SMACD)*, pages 1–4, Villasimius, Sardinia, Italy, 2022.
- [NBF⁺21] G. Nicolae, A. Buzo, C. Feuerbaum, C.V. Diaconu, H. Cucu, G. Pelz, and C. Burileanu. Metamodel-based prediction of on resistance for microelectronic power switches. In *2021 IEEE Electrical Design of Advanced Packaging and Systems (EDAPS)*, pages 1–3, Virtual Conference, 2021.
- [NCB⁺23] G. Nicolae, H. Cucu, C. Burileanu, A. Buzo, C. Feuerbaum, and G. Pelz. Automatic design optimization of microelectronic power switches. *UNIVERSITY POLITEHNICA OF BUCHAREST SCIENTIFIC BULLETIN SERIES C-ELECTRICAL ENGINEERING AND COMPUTER SCIENCE*, 85(1):377–388, 2023.
- [Nic18] G. Nicolae. Sensitivity analysis on electro-thermal limit of safe operating area in power mosfets. Master’s thesis, University Politehnica of Bucharest, 2018.

- [Nic19a] G. Nicolae. A machine learning approach for mesh optimization in thermal analysis of semiconductor packages. *Technical Report No. 2, University Politehnica of Bucharest*, December 2019.
- [Nic19b] G. Nicolae. Optimization of power electronics packaging, fabrication process and device simulation. *Technical Report No. 1, University Politehnica of Bucharest*, June 2019.
- [Nic20] G. Nicolae. Multi-objective optimization of electronic packages. *Technical Report No. 3, University Politehnica of Bucharest*, June 2020.
- [PJS08] Martin Pfof, Joachim Joos, and Matthias Stecher. Measurement and simulation of self-heating in dmos transistors up to very high temperatures. In *2008 20th International Symposium on Power Semiconductor Devices and IC's*, pages 209–212, 2008.
- [PP02] A. Papoulis and S.U. Pillai. *Probability, Random Variables, and Stochastic Processes*. McGraw-Hill series in electrical engineering: Communications and signal processing. McGraw-Hill, 2002.
- [Rin01] N. Rinaldi. On the modeling of the transient thermal behavior of semiconductor devices. *IEEE Transactions on Electron Devices*, 48(12):2796–2802, 2001.
- [Wan17] Li-C. Wang. Experience of data analytics in eda and test—principles, promises, and challenges. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 36(6):885–898, 2017.