

کاربرد نگاشت فضایی عصبی در مدل سازی ادوات نیمه‌هادی

مهدی گردی ارمکی، سید ابراهیم حسینی و محمدکاظم انوری فرد

تقویت کننده‌های فرکانس بالا [۵] استفاده شده‌اند. همچنین با این روش‌ها مدل سازی عملکرد غیر خطی MOSFET، MESFET و HEMT نیز در [۶] و [۷] بررسی شده است. در [۸] نیز پاسخ گذرای دروازه‌های منطقی MOSFET از نوع GaAs با روش MLP مدل سازی و بررسی شده است. در این مقاله هدف، پیداکردن نگاشت فضایی عصبی مابین مدل تقریبی و مدل دقیق ادوات نیمه‌هادی است تا بدین صورت پارامترهای نادقیق به دست آمده توسط مدل تقریبی به پارامترهای دقیق‌تر تبدیل شوند.

با توجه به ماهیت غیر خطی معادلات نیمه‌هادی، این نگاشت بر مبنای شبکه عصبی می‌باشد. نگاشت فضایی عصبی (NSM) از سال ۱۹۹۹ تاکنون کاربرد وسیعی در طراحی مدارات فرکانس بالا پیدا کرده است [۹] و [۱۰].

در بخش ۲ این مقاله دو روش مدل سازی تقریبی و دقیق به کار رفته، معرفی شده است. سپس در بخش ۳ خصوصیات شبکه عصبی پیشنهادی و نحوه مدل سازی توضیح داده شده است. همچنین در بخش ۴ نیز نتایج شبیه سازی برای دیود $n-i-n$ در حالت یک‌بعدی بررسی شده است.

۲- مدل تقریبی و دقیق

معادله انتقال بولتزمن در شبیه سازی افزاره‌های نیمه‌هادی، کاربردی وسیع دارد [۱۱]. روش متداول حل معادله بولتزمن استفاده از مومنت‌های معادله موازنه (بقا) می‌باشد [۱۲]. این معادلات عبارتند از

$$\frac{\partial n}{\partial t} + \nabla \cdot (n \mathbf{v}) = G \quad (1)$$

$$\frac{\partial(m^* n \mathbf{v})}{\partial t} + \frac{1}{\tau_p} \nabla \cdot (w) + qn \mathbf{E} = \frac{-m^* n \mathbf{v}}{\tau_p} \quad (2)$$

$$\frac{\partial(nw)}{\partial t} = qn \mathbf{v} \mathbf{E} - \nabla \cdot (nw \mathbf{v} + nK_B T \mathbf{v}) - \frac{n(w - w_0)}{\tau_w} + wG \quad (3)$$

که (۱)، (۲) و (۳) به ترتیب معادله بقای ذره، بقای مومنتم و بقای انرژی می‌باشد. در روابط فوق $G = \alpha(mv^2 + 3kT)$ نرخ بازترکیب، m جرم مؤثر الکترون، v سرعت الکترون، q اندازه بار الکترون، \mathbf{E} میدان الکتریکی، T دمای الکترون و τ_p زمان واهلش مومنتم می‌باشد. برای مدل سازی پارامترهای نیمه‌هادی، معادلات بالا به همراه معادله پواسون حل می‌شوند

$$\nabla^2 \Psi = -\frac{q}{\epsilon} (N_D - n) \quad (4)$$

در صورتی که دمای الکترون (انرژی الکترون) ثابت فرض شود دیگر نیازی به حل (۳) نخواهد بود و یک مدل تقریبی برای شبیه سازی به دست می‌آید. مدل تقریبی آسان تر و سریع تر است، اما در شبیه سازی افزاره‌های

چکیده: در این مقاله روش جدید و کارآمدی برای مدل سازی دقیق افزاره‌های نیمه‌هادی با استفاده از مدل تقریبی و به کمک شبکه عصبی ارائه شده است. بر خلاف مدل‌های دقیق که دارای پیچیدگی بالا و هزینه زمانی و پردازشی زیادی هستند، روش پیشنهادی از پیچیدگی کمتر و سرعت پردازش بیشتری برخوردار است. در این روش از شبکه عصبی RBF برای محاسبه پارامتر اصلاحی در مدل نفوذ-رائش استفاده شده است. بدین صورت حل مدل تقریبی اصلاح شده منجر به جواب دقیق می‌شود. روش پیشنهادی ابتدا برای دیود $n-i-n$ سیلیکونی به صورت یک‌بعدی و سپس برای ترانزیستور اثر میدانی سیلیکونی به صورت دوبعدی برای دو حالت درون یابی و برون یابی در رنج محدود، شبیه سازی شده است که نتایج آن برای متغیرهای اساسی مدل، مثل توزیع الکترون و پتانسیل در طول افزاره در ولتاژهای مختلف، دقت بالای روش پیشنهادی را تأیید می‌کند.

کلید واژه: شبکه عصبی RBF، نگاشت فضایی عصبی، مدل سازی نیمه‌هادی، معادله بولتزمن.

۱- مقدمه

مدل سازی افزاره‌های نیمه‌هادی نقش مهمی در بهبود روش‌های طراحی و درک بهتر آنها دارد. لذا این روش‌ها همواره در حال تکامل می‌باشند. برای به دست آوردن پارامترهای نیمه‌هادی دو گروه کلی برای روش‌های مدل سازی می‌توان متصور شد: ۱- استفاده از مدل تقریبی که منجر به حل نادقیق و تقریبی پارامترهای نیمه‌هادی می‌شود. ۲- استفاده از مدل دقیق که البته در کنار دقت، پیچیدگی بیشتری دارند و مستلزم صرف زمان و هزینه پردازشی بالاتری هستند. اما در مدل تقریبی علی‌رغم داشتن نقص نادقیق بودن، پیچیدگی مسأله کمتر و سرعت محاسبات بیشتر می‌باشد.

از زمان به وجود آمدن افزاره‌های نیمه‌هادی تاکنون، سرعت آنها افزایش چشم‌گیری پیدا کرده و طول کانال این افزاره‌ها همواره کوچک تر شده است، به طوری که طول کانال افزاره‌های نیمه‌هادی کنونی، در مرز ۴۵ نانومتر قرار دارد [۱] و [۲]. هرچه طول کانال کوچک تر شود، تفاوت نتایج حاصل از روش مدل سازی دقیق و تقریبی افزایش می‌یابد، به طوری که در افزاره‌های با طول کانال خیلی کوچک حتماً باید اثرات مرتبه بالا و کوانتومی اعمال شود.

شبکه‌های عصبی مصنوعی، ابزارهای محاسباتی هوشمندی هستند که تاکنون جهت مدل سازی، شبیه سازی و بهینه سازی مدارات فرکانس بالا [۳]، مدل سازی و بهینه سازی اتصالات داخلی مدارات VLSI [۴] و

این مقاله در تاریخ ۱۲ مرداد ماه ۱۳۸۸ دریافت و در تاریخ ۱۰ خرداد ماه ۱۳۸۹ بازنگری شد.

مهدی گردی ارمکی، دانشکده فنی و مهندسی، دانشگاه تربیت معلم سبزوار، سبزوار، کدپستی ۹۶۱۷۶۳۸۴۵۴ (email: me.ko.ar@gmail.com).

سید ابراهیم حسینی، دانشکده فنی و مهندسی، دانشگاه تربیت معلم سبزوار، سبزوار، کدپستی ۹۶۱۷۶۳۸۴۵۴ (email: ehosseini@sttu.ac.ir).

محمدکاظم انوری فرد، دانشکده فنی و مهندسی، دانشگاه تربیت معلم سبزوار، سبزوار، کدپستی ۹۶۱۷۶۳۸۴۵۴ (email: m.anvarifard@gmail.com).

خروجی‌های طبقه RBF را می‌سازد. در اکثر موارد از توابع گوسی در لایه میانی استفاده می‌شود که این توابع با دو پارامتر مرکز گوسی و واریانس یا میزان گستردگی گوسی شناسایی می‌شوند. ساختمان یک شبکه RBF در شکل ۱ مشاهده می‌شود.

عملیاتی که در این شبکه انجام می‌شود در فرم ماتریسی به صورت (۸) و (۹) است

$$d_i(P) = \sum_{j=1}^N \varphi_j(P) w_{ij} \quad (8)$$

$$\varphi_j = \exp\left(-\frac{1}{\sigma_j^2} \|P - C_j\|^2\right) \quad (9)$$

که در آن $d_i(P)$ خروجی i ام شبکه و φ_j خروجی گره RBF j ام به‌ازای بردار ورودی P است. w_{ij} نیز اتصال سیناپسی میان آن دو است. تعداد کل نرون‌های لایه پنهان نیز N است. بردار C_j را مرکز گوسی می‌نامیم و σ_j نیز مشخص‌کننده میزان گستردگی گوسی است.

آموزش شبکه مذکور بدین صورت است که باید مقادیر مناسبی را C_j و σ_j برای یافته و وزنهای لایه خطی آخر نیز به درستی تنظیم شوند. همچنین تعداد نرون‌ها در لایه میانی نیز باید مشخص شود.

۳-۲ نحوه ایجاد نگاشت

یکی از روش‌ها برای ایجاد نگاشت ما بین مدل دقیق و تقریبی، اصلاح پارامترهایی از مدل تقریبی است که باعث شود حل مدل تقریبی به نتایج دقیق‌تری منجر شود. در نگاشت فضایی پیشنهادی، توزیع پارامتر β (۷) با شبکه عصبی به‌نحوی مدل‌سازی می‌شود که نتایج حل مدل تقریبی و دقیق با هم برابر (یا بسیار نزدیک) باشند. شکل ۲ نمودار نگاشت فضایی عصبی پیشنهادی را نشان می‌دهد.


با توجه به (۴) و (۷) برای یک افزاره تک‌قطبی حامل الکترون، متغیرهای اصلی، توزیع الکترون (n)، توزیع پتانسیل (ψ) و پارامتر اصلاحی (توزیع β) می‌باشند. بنابراین اگر بتوان یکی از دو متغیر n یا ψ را با پارامتر اصلاحی β دقیق‌تر محاسبه کرد، متغیر دیگر نیز به‌صورت دقیق‌تر از حل معادله پواسون به‌دست می‌آید. همچنین از آنجایی که $\beta \Delta v$ در (۷) تعیین‌کننده میزان جریان است، بنابراین برای آموزش β از توزیع ψ استفاده شده است. برای این که تضمین شود جریان‌ها در دو مدل دقیق و تقریبی با هم برابر می‌شوند، بعد از هر محاسبه β جریان نیز از (۷) به‌دست آمده و با جریان دقیق مقایسه می‌شود. بنابراین اختلاف جریان‌ها هم در آموزش شبکه مؤثر است.

شبکه عصبی مورد استفاده RBF می‌باشد، زیرا در صورت آموزش صحیح و انتخاب مناسب پارامترها، برای یادگیری هر تابعی با تعداد محدودی ناپوستگی و هر دقتی کفایت می‌کند [۱۴] و [۱۵]. از آنجا که امکان محاسبه با دقت مناسب برای مشتقات جزئی تابع خطا نسبت به پارامترهای مدل وجود ندارد و نیز به‌منظور فرار از کمینه‌های محلی، از روش آموزش تصادفی برای آموزش شبکه استفاده شده است.

۴- شبیه‌سازی و نتایج

۴-۱ شبیه‌سازی دیود n-i-n

در این قسمت نتایج شبیه‌سازی نگاشت فضایی عصبی برای دیود n-i-n از جنس سیلیکون در حالت یک‌بعدی ارائه شده است. طول دیود nm ۱۰۰ با ۶۰ نقطه مش که به‌صورت یک‌نواخت در آن توزیع شده است. مشخصات دیود مذکور در شکل ۳ آمده است.



شکل ۱: نمودار شبکه عصبی RBF به‌کار رفته.

با ابعاد کوچک دقت کافی را ندارد. استفاده از معادله انرژی دقت شبیه‌سازی را افزایش می‌دهد، اما از طرفی زمان شبیه‌سازی بیشتر شده و گذشته از آن پیچیدگی حل عددی افزایش می‌یابد. پس در این تحقیق، مدل تقریبی حل هم‌زمان معادلات (۱)، (۲) و (۴) در نظر گرفته شده است. در این مدل تقریبی جریان در جهت x در حالت پایدار، از دو معادله اول چنین به‌دست می‌آید

$$J_x = q \mu_x n E_x + q D_x \frac{\partial n}{\partial x} \quad (5)$$

که D_x و μ_x به ترتیب قابلیت تحرک و ضریب نفوذ الکترون در جهت x می‌باشند. همچنین در مدل دقیق نیز حل هم‌زمان معادلات (۱) تا (۴) در نظر شده گرفته است که در این حالت جریان پایدار در جهت x چنین به‌دست می‌آید

$$J_x = q \mu_x n E_x - S q \mu_x K_B T \frac{\partial n}{\partial x} - S q \mu_x K_B T \frac{\partial T_x}{\partial x} \quad (6)$$

که S فلوی انرژی می‌باشد. با توجه به این که محدوده تغییرات متغیرها بسیار بزرگ است، تغییر مقیاس در متغیرها صورت گرفته و برای حل عددی معادلات از روش تفاضل محدود استفاده شده است. به‌منظور افزایش همگرایی معادلات در تغییرات شدید میدان الکتریکی، معادله جریان باید به فرم نمایی نوشته شود، بنابراین (۵) در حالت گسسته چنین خواهد بود

$$J_x = \frac{D_x}{h} (FB(-\beta_x \Delta v) n_{i,j} - FB(\beta_x \Delta v) n_{i+1,j}) \quad (7)$$

که β_x و FB چنین تعریف می‌شود

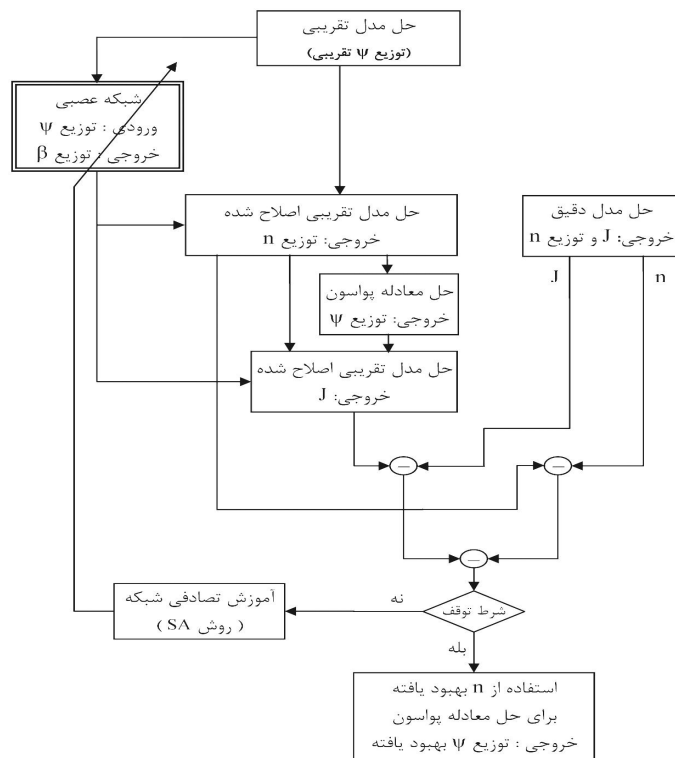
$$\beta_x = \frac{\mu_x}{D_x}, \quad FB(x) = \frac{x}{1 - \exp(x)}$$

۳- نگاشت فضایی عصبی

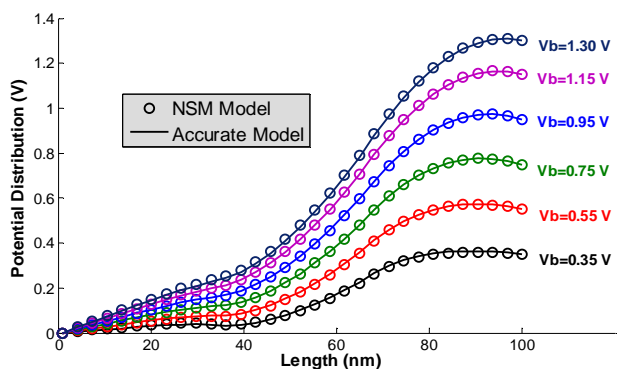
۳-۱ شبکه عصبی RBF

توانایی یادگیری و تعمیم داده‌ها، خاصیت پردازش غیر خطی و ساختار پردازش موازی همگی مزایایی است که باعث می‌شود از شبکه‌های عصبی در مدل‌سازی با ابعاد بالا و مسایل غیر خطی زیادی از جمله معادلات نیمه‌هادی استفاده شود [۱۳].

یکی از مهم‌ترین شبکه‌های عصبی مورد استفاده در مسایل تخمین تابع، شبکه عصبی RBF است. این نوع شبکه نسبت به شبکه‌های عصبی پرسپترون پیش‌خوردی، مزایای زیادی دارد [۱۴]. برخلاف شبکه‌های MLP که می‌توانند دارای لایه‌های متوالی متعددی باشند، شبکه RBF تنها از سه لایه ثابت تشکیل شده است. لایه ورودی که محل تزریق سیگنال‌های ورودی به شبکه است؛ لایه میانی یا طبقه RBF که شامل توابع شعاعی پایه می‌شود و لایه خروجی که ترکیبی خطی از کلیه




شکل ۲: نمودار نگاهت فضایی عصبی پیشنهادی.




شکل ۵: توزیع پتانسیل در طول دیود n-i-n برای بایاس ۰.۳۵-۰.۷۵-۰.۹۵-۱.۱۵-۱.۳ ولت.

$n +$	n	$n +$
$N_D = 1e18 \text{ cm}^{-3}$	$N_D = 1e15 \text{ cm}^{-3}$	$N_D = 1e18 \text{ cm}^{-3}$
Length = 33 nm	Length = 34 nm	Length = 33 nm
Num.Mesh = 20	Num.Mesh = 20	Num.Mesh = 20

شکل ۳: ساختار دیود n-i-n شبیه سازی شده.



شکل ۴: توزیع الکترون در طول دیود n-i-n برای بایاس ۰.۳۵-۰.۷۵-۰.۹۵-۱.۱۵-۱.۳ ولت.



شکل ۶: توزیع β (خروجی شبکه عصبی RBF) برای ولتاژ بایاس ۱.۱۵ ولت به عنوان نمونه.


شکل ۶ چگونگی توزیع β را برای یکی از نمونه های آزمون نشان می دهد. از روی توزیع β می توان به چگونگی تصحیح مدل تقریبی توسط β پی برد.

همان طور که دو شکل ۴ و ۵ نشان می دهند، نتایج مدل اصلاح شده بسیار به مدل دقیق نزدیک است. جدول ۱ مقادیر نرم خطا در ولتاژهای مختلف و نیز درصد خطای ایجاد شده با مدل پیشنهادی برای دو حالت چگالی الکترون و پتانسیل را نشان می دهد.


برای شبیه سازی ابتدا با مدل تقریبی و دقیق، مقادیر n و ψ برای ولتاژهای بایاس ۰.۱ تا ۱.۲ با گام ۰.۱۵ ولت محاسبه و ذخیره شده است. از ۲۳ نمونه مذکور، ولتاژهای ۰.۳۵-۰.۷۵-۰.۹۵-۱.۱۵ ولت به عنوان داده آزمون و بقیه به عنوان داده آموزش استفاده شده اند. همچنین برای حالت برون یابی ولتاژ ۱.۲۵ و ۱.۳۰ ولت نیز به نمونه های آزمون فوق افزوده شدند.

بعد ورودی و خروجی شبکه عصبی RBF استفاده شده ۶۰ و نیز از ۱۰ نرون در لایه پنهان استفاده شده و آموزش شبکه با الگوریتم شبیه سازی گرمایی [۱۶] صورت گرفته است.

شکل های ۴ و ۵ چگالی الکترون و پتانسیل را برای ولتاژهای آزمون برای دو حالت مدل دقیق و مدل پیشنهادی (نگاشت فضایی عصبی) نشان می دهد.



شکل ۱۰: توزیع پتانسیل در طول ترانزیستور (زیر گیت) برای ولتاژهای $V_b = 0.5$ و $V_g = 1.2$.



شکل ۱۱: توزیع الکترون در طول ترانزیستور (زیر گیت) برای ولتاژهای $V_b = 1$ و $V_g = 1.4$.

جدول ۱: خطای مدل سازی برای دیود N-I-N سیلیکونی شبیه سازی شده.

توزیع ψ	توزیع n	نرم خطا در ولتاژهای
۰.۰۹	۰.۰۳۶	$V_b = 0.35$ V
۰.۰۱۶	۰.۰۳۶	$V_b = 0.55$ V
۰.۰۱۹	۰.۰۲۲	$V_b = 0.75$ V
۰.۰۱۱	۰.۰۲	$V_b = 0.95$ V
۰.۰۲۲	۰.۰۴۳	$V_b = 1.15$ V
۰.۰۱۶	۰.۰۴۶	$V_b = 1.25$ V
۰.۰۱	۰.۰۴۲	$V_b = 1.3$ V

$$V_{gate} = 1.4, V_{ds} = 0.2, 0.4, 0.6, 0.8, 1.0, 1.2$$

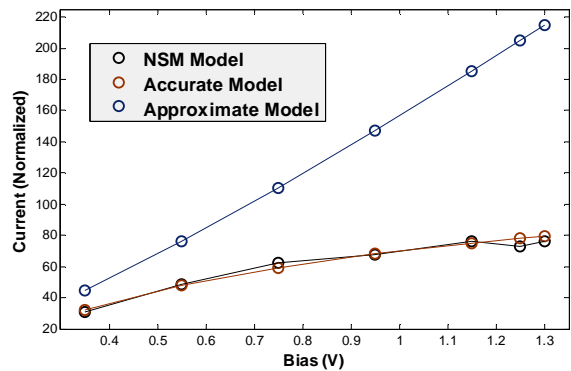
نیز به مجموعه آزمون افزوده شدند.

به علت افزایش همگرایی از دو شبکه عصبی RBF موازی با ۲۰ نرون در لایه پنهان و با بُعد ورودی ۱۶۰ (۲۰×۸۰) و خروجی ۸۰ برای تولید β استفاده شده و آموزش شبکه با الگوریتم شبیه سازی گرمایی [۱۶] صورت گرفته است.


شکل های ۹ و ۱۰ چگالی الکترون و پتانسیل را برای ولتاژ گیت ۱.۲ و ولتاژ بایاس ۰.۵ برای سه حالت مدل تقریبی، مدل دقیق نگاهت فضایی عصبی در زیر گیت (اولین سطر ماتریس دوعبده) به عنوان نمونه ای از نتیجه درون یابی نشان می دهد.

این دو شکل نشان می دهند که نگاهت به خوبی می تواند نتایج مدل دقیق را تولید کند. این در حالی است که نتایج مدل تقریبی اختلاف قابل توجهی با نتایج دقیق دارد.


شکل های ۱۱ و ۱۲ چگالی الکترون و پتانسیل را برای ولتاژ گیت ۱.۴ و ولتاژ بایاس ۱.۰ V به عنوان نمونه ای از نتیجه درون یابی نشان می دهند. در شکل ۱۱ تنها در بخش های کمی از کانال، اختلاف اندک بین مدل دقیق و نگاهت فضایی عصبی دیده می شود، در حالی که مدل تقریبی نتایج کاملاً نادقیق دارد.



شکل ۷: جریان دیود n-i-n در بایاس های $0.35 - 0.55 - 0.75 - 0.95 - 1.15 - 1.25$ - برای سه مدل تقریبی، دقیق و نگاهت فضایی عصبی.



شکل ۸: ساختار ترانزیستور اثر میدانی با گیت نازک شبیه سازی شده.



شکل ۹: توزیع الکترون در طول ترانزیستور (زیر گیت) برای ولتاژهای $V_b = 0.5$ و $V_g = 1.2$.

شکل ۷ میزان دقت جریان به دست آمده توسط نگاهت فضایی عصبی را در مقایسه با مدل تقریبی نشان می دهد. جریان در مدل پیشنهادی از (۷) به دست آمده است.

۴-۲ شبیه سازی ترانزیستور اثر میدانی

در این قسمت نتایج شبیه سازی نگاهت فضایی عصبی برای ترانزیستور اثر میدانی از جنس سیلیکون در حالت دوعبده ارائه شده است. طول ترانزیستور ۱۰۰ nm با ۲۰ مش و عرض آن نیز ۲۰ nm با ۸ نقطه مش است که مش ها در آن به طور یکنواخت توزیع شده اند. مشخصات ترانزیستور مذکور در شکل ۸ آمده است.


برای شبیه سازی ابتدا با مدل تقریبی و دقیق، مقادیر دوعبده n و ψ برای ولتاژهای ۰.۱ تا ۱.۳ ولت با گام ۰.۱ برای گیت و ولتاژ درین محاسبه و ذخیره می شوند. از مجموع ۱۶۹ نمونه مذکور، ۱۸ مجموعه ولتاژ یعنی

$$V_{gate} = 0.6, V_{ds} = 0.3, 0.5, 0.7, 0.9, 1.1, 1.3$$

$$V_{gate} = 0.9, V_{ds} = 0.2, 0.4, 0.6, 0.8, 1.0, 1.2$$

$$V_{gate} = 1.2, V_{ds} = 0.3, 0.5, 0.7, 0.9, 1.1, 1.3$$

برای آزمون و مابقی برای آموزش استفاده شده است. نحوه انتخاب نمونه های آزمون با توجه به میزان خطای مدل تقریبی بوده و محدوده ولتاژهایی انتخاب شده اند که بیشترین خطا را در مدل تقریبی داشته باشند. همچنین برای آزمایش برون یابی شبکه، ۶ ولتاژ



شکل ۱۴: توزیع پارامتر اصلاحی در جهت y برای ولتاژ آزمون $V_b = ۱,۳$ و $V_g = ۱,۲$ (سمت چپ شکل)

جدول ۳: خطای توزیع الکترون در ترانزیستور شبیه‌سازی شده.

V_{gate}	V_b (v)	۰,۳	۰,۵	۰,۷	۰,۹	۱,۱	۱,۳
		Δ	۱,۸۶	۳,۷۴	۵,۷۳	۷,۴۵	۸,۴۹
$V_{gate} = ۰,۹$ v	\square	۰,۶۱	۰,۶۱	۰,۴۵	۰,۳۶	۰,۴۹	۰,۹۵
	\otimes	۱,۵۲	۱,۲۱	۰,۸۹	۰,۶۸	۰,۷۶	۱,۰۴
	V_b (v)	۰,۲	۰,۴	۰,۶	۰,۸	۱,۰	۱,۲
$V_{gate} = ۱,۲$ v	Δ	۳,۶۴	۷,۸۴	۱۱,۸	۱۴,۹	۱۶,۶	۱۷,۰
	\square	۰,۷۱	۰,۶۸	۰,۷۷	۰,۷۷	۱,۰۷	۰,۵۹
	\otimes	۱,۲۹	۰,۹۴	۰,۸۱	۰,۷۱	۰,۸۱	۰,۵۴
$V_{gate} = ۱,۳$ v	Δ	۱۲,۷	۱۵,۶	۱۸,۶	۲۰,۷	۲۱,۵	۲۱,۱
	\square	۰,۸۶	۲,۳۱	۱,۸۳	۱,۴۸	۱,۳۷	۲,۲۹
	\otimes	۰,۸۳	۱,۱۷	۰,۹۹	۰,۸۵	۰,۸۰	۱,۰۳
$V_{gate} = ۱,۴$ v	Δ	۱۴,۳	۲۱,۶	۲۲,۸	۲۳,۶	۲۴,۱	۲۳,۷
	\square	۳,۲۵	۶,۶۴	۳,۳۰	۶,۶۷	۵,۶۹	۴,۵۰
	\otimes	۱,۳۵	۱,۴۹	۱,۱۶	۱,۴۵	۱,۳۷	۱,۲۷
		Δ	\square	\otimes			
		نرم خطا در مدل تقریبی	نرم خطا در مدل پیشنهادی	درصد خطا در مدل پیشنهادی			


که در آن پارامتر $RSSE_{NSM}$ نرم خطا (جذر مجموع مربعات خطا) در مدل پیشنهادی (نگاشت فضایی عصبی) و $RSSE_{App}$ نرم خطا در مدل تقریبی می‌باشد.

جدول ۴ مقدار خطای جریان (نرمالیزه شده) برای دو مدل تقریبی و مدل نگاشت فضایی در ولتاژهای مختلف را نشان می‌دهد. همان‌طور که از این جدول دیده می‌شود، مدل نگاشت فضایی عصبی به مراتب خطایی کمتر از مدل تقریبی دارد.


همچنین شبیه‌سازی این ترانزیستور با طول ۳۰۰ نانومتر نیز انجام شده است و نتایج مشابهی به دست آمده است. با توجه به شباهت بسیار زیاد نتایج این دو ترانزیستور و نیز جلوگیری از طولانی شدن و تکراری شدن قسمت نتایج، از اضافه کردن آن خودداری شده است.

۵- نتیجه گیری

در این مقاله روش جدیدی برای مدل‌سازی افزاره‌های نیمه‌هادی با پیچیدگی کمتر توسط نگاشت فضایی عصبی ارائه شده است. برای این منظور از یک شبکه عصبی پیش‌خور تک‌لایه جهت مدل‌سازی پارامتر اصلاحی در معادله نفوذ-رانس استفاده شده است. دو افزاره دیود $n-i-p$ سیلیکونی و ترانزیستور اثر میدانی سیلیکونی در ولتاژهای مختلف شبیه‌سازی شده‌اند که نتایج برای دو حالت درون‌یابی و برون‌یابی در رنج



شکل ۱۲: توزیع پتانسیل در طول ترانزیستور (زیر گیت) برای ولتاژهای $V_b = ۱$ و $V_g = ۱,۴$.



شکل ۱۳: توزیع پارامتر اصلاحی در جهت x برای ولتاژ آزمون $V_b = ۱,۳$ و $V_g = ۱,۲$ (سمت چپ شکل)

جدول ۲: خطای توزیع پتانسیل در ترانزیستور شبیه‌سازی شده.

V_{gate}	V_b (v)	۰,۳	۰,۵	۰,۷	۰,۹	۱,۱	۱,۳
		Δ	۰,۲۲	۰,۴۶	۰,۷۷	۱,۰۹	۱,۳۲
$V_{gate} = ۰,۹$ v	\square	۰,۱۱	۰,۱۱	۰,۰۹	۰,۰۶	۰,۰۶	۰,۱۳
	\otimes	۱,۶۹	۱,۳۶	۱,۰۸	۰,۷۴	۰,۶۶	۰,۹۶
	V_b (v)	۰,۲	۰,۴	۰,۶	۰,۸	۱,۰	۱,۲
$V_{gate} = ۱,۲$ v	Δ	۱,۸۱	۱,۸۰	۱,۹۶	۲,۲۱	۲,۴۳	۲,۵۴
	\square	۰,۲۰	۰,۱۵	۰,۱۸	۰,۲۱	۰,۱۸	۰,۱۶
	\otimes	۱,۰۵	۰,۹۲	۰,۹۸	۰,۹۸	۰,۸۷	۰,۷۹
$V_{gate} = ۱,۳$ v	Δ	۱۲,۳	۱۰,۴	۸,۹۹	۸,۰۸	۷,۴۰	۶,۸۳
	\square	۰,۴۱	۰,۴۷	۰,۲۸	۰,۲۱	۰,۲۷	۰,۳۶
	\otimes	۰,۵۲	۰,۶۵	۰,۵۰	۰,۴۲	۰,۵۶	۰,۷۳
$V_{gate} = ۱,۴$ v	Δ	۲۰,۴	۲۲,۲	۱۸,۶	۱۵,۹	۱۴,۰	۱۲,۶
	\square	۵,۱۱	۲,۳۸	۱,۰۵	۱,۴۴	۱,۴۰	۱,۰۰
	\otimes	۱,۴۰	۱,۰۳	۰,۷۵	۰,۹۶	۱,۰۰	۰,۹۰
		Δ	\square	\otimes			
		نرم خطا در مدل تقریبی	نرم خطا در مدل پیشنهادی	درصد خطا در مدل پیشنهادی			

مقدار جریان بهبود یافته نیز از (γ) حاصل می‌شود. شکل ۱۳ و ۱۴ به ترتیب توزیع دو پارامتر اصلاحی β در جهت x (β_x) و در جهت y (β_y) را برای یک ولتاژ به عنوان نمونه نشان می‌دهد.

همان‌طور که شکل‌های ۹، ۱۰، ۱۱ و ۱۲ نشان می‌دهند، نتایج مدل پیشنهادی بسیار به مدل دقیق نزدیک است. جداول ۲ و ۳ مقادیر نرم خطا در ولتاژهای مختلف و نیز درصد خطای ایجاد شده با مدل پیشنهادی را برای دو حالت چگالی الکترون و پتانسیل نشان می‌دهند که درصد خطای مدل پیشنهادی از فرمول زیر محاسبه شده است

$$\text{Error} = \log \left(100 \times \frac{RSSE_{App}}{RSSE_{NSM}} \right) \quad (۱۰)$$

جدول ۴: خطای جریان نرمالیزه شده ترانزیستور برای مدل تقریبی و مدل نگاشت فضایی عصبی.

		V_b (v)						
		۰٫۳	۰٫۵	۰٫۷	۰٫۹	۱٫۱	۱٫۳	
V_{gate}	۰٫۶	مدل تقریبی	۰٫۰۴۸	۰٫۰۹۴	۰٫۱۵۳	۰٫۲۲۷	۰٫۳۱۴	۰٫۴۱۷
		NSM مدل	۰٫۰۱۱	۰٫۰۱۴	۰٫۰۱۶	۰٫۰۱۵	۰٫۰۱۸	۰٫۰۳۹
	۱٫۲	مدل تقریبی	۱٫۲۱۱	۲٫۲۳۱	۳٫۰۱۲	۳٫۶۷۹	۴٫۲۸۷	۴٫۸۵۶
		NSM مدل	۰٫۰۹۴	۰٫۲۴۱	۰٫۲۷۳	۰٫۲۵۲	۰٫۳۰۴	۰٫۳۵۵
		V_b (v)						
		۰٫۲	۰٫۴	۰٫۶	۰٫۸	۱٫۰	۱٫۲	
V_{gate}	۰٫۹	مدل تقریبی	۰٫۲۴۸	۰٫۵۸۹	۰٫۹۰۷	۱٫۲۲۶	۱٫۵۴۹	۱٫۸۷۷
		NSM مدل	۰٫۰۴۷	۰٫۰۸۲	۰٫۰۹۱	۰٫۰۸۹	۰٫۱۰۲	۰٫۱۸۱
	۱٫۴	مدل تقریبی	۰٫۸۶۰	۲٫۴۸۲	۳٫۹۲۳	۵٫۰۲۷	۵٫۹۲۲	۶٫۷۰۴
		NSM مدل	۰٫۱۳۴	۰٫۳۳۰	۰٫۲۹۱	۰٫۴۲۳	۰٫۳۸۱	۰٫۵۳۹

- [13] S. Hatami, M. Y. Azizi, H. R. Bahrami, D. Motavalizadeh, and A. Afzali - Kusha, "Accurate and efficient modeling of SOI MOSFET with technology independent neural networks," *IEEE Trans. on Computer Aided Design of Integrated Circuits and Systems*, vol. 23, no. 11, pp. 1580-1587, Nov. 2004.
- [14] S. Heykin, *Neural Networks: A Comprehensive Foundation*, Prentice Hall, 2nd Edition, 1998.
- [15] C. Christodoulou and M. Georgiopoulos, *Applications of Neural Networks in Electromagnetics*, Artech House Publishers, 2001.
- [16] B. Goffe, G. Ferrier, and J. Rogers, "Global optimization of statistical function with simulated annealing," *J. Econometrics*, vol. 60, no. 1-2, pp. 65-100, Jan./Feb. 1994.

مهدی گردی ارمکی در سال ۱۳۸۴ مدرک کاردانی را در رشته الکترونیک ناوبری هواپیما (اویونیک) از دانشگاه صنعت هواپیمایی کشوری و نیز به ترتیب در سالهای ۱۳۸۶ و ۱۳۸۸ مدرک کارشناسی و کارشناسی ارشد مهندسی برق را در گرایش الکترونیک از دانشگاه تربیت معلم سبزوار اخذ کرده است. وی تجربیاتی در زمینه مدل سازی ادوات نیمه هادی و مدارات مجتمع و برخی روشهای هوش مصنوعی داشته و علاقه فراوانی به تلفیق روشهای هوشمند با انواع روشهای کلاسیک در حوزه الکترونیک جهت افزایش کارایی دارد.

سید ابراهیم حسینی در سال ۱۳۷۱ مدرک کارشناسی مهندسی برق خود را از دانشگاه صنعتی اصفهان و در سال ۱۳۷۴ مدرک کارشناسی ارشد مهندسی برق-الکترونیک خود را از دانشگاه تربیت مدرس دریافت نمود. سپس برای ادامه تحصیل در دوره دکترای مهندسی برق وارد دانشگاه صنعتی شریف گردید و در سال ۱۳۸۰ موفق به اخذ درجه دکترا در مهندسی برق-الکترونیک با گرایش نیمه هادی از دانشگاه مذکور گردید. دکتر حسینی از سال ۱۳۸۰ در دانشکده برق دانشگاه صنعتی شاهرود مشغول به فعالیت گردید. سپس در سال ۱۳۸۴ به دانشکده فنی دانشگاه تربیت معلم سبزوار پیوست و اینک نیز عضو هیأت علمی این دانشکده می باشد. زمینه های علمی مورد علاقه نام برده انتقال الکترون در ادوات نیمه هادی، شبیه سازی ادوات نیمه هادی، روشهای عددی و ساختارهای نوین ترانزیستوری می باشد.

محمد کاظم انوری فرد در سال ۱۳۸۶ مدرک کارشناسی مهندسی برق خود را از دانشگاه آزاد اسلامی واحد لاهیجان و در سال ۱۳۸۸ مدرک کارشناسی ارشد مهندسی برق خود را از دانشگاه تربیت معلم سبزوار دریافت نمود. از سال ۱۳۸۶ الی ۱۳۸۸ نام برده ضمن تحصیل به عنوان مدرس دانشگاه در دانشگاه تربیت معلم سبزوار مشغول به کار شد و هم اکنون نیز مدرس دانشگاه آزاد رامسر و آموزشکده فنی رامسر و موسسه غیرانتفاعی آیندگان تنکابن می باشد. زمینه های علمی مورد علاقه ایشان متنوع بوده و شامل موضوعاتی مانند افزارهای نیمه هادی، روش های تحلیلی در ارزیابی ادوات و همچنین پردازش تصویر می باشد.

محدود، نشان دهنده کارایی بالای مدل پیشنهادی برای پارامترهای مختلف افزاره از قبیل توزیع الکترون و پتانسیل می باشد.

مراجع

- [1] A. Khakifirooz and D. Antoniadis, "MOSFET performance scaling, part I: historical trends," *IEEE Trans. on Electron Devices*, vol. 55, no. 6, pp. 1401-1408, Nov. 2008.
- [2] A. Khakifirooz and D. Antoniadis, "MOSFET performance scaling, part II: future directions," *IEEE Trans. on Electron Devices*, vol. 55, no. 6, pp. 1391-1400, Nov. 2008.
- [3] Q. J. Zhang and K. C. Gupta, *Neural Networks for RF and Microwave Design*, Norwood, MA: Artech House, 2000.
- [4] A. Veluswami, M. S. Nakhla, and Q. J. Zhang, "The application of neural networks to EM-based simulation and optimization of interconnects in high-speed VLSI circuits," *IEEE Trans. Microwave Theory Tech.*, vol. 45, no. 5, pp. 712-723, May 1997.
- [5] Y. Harkouss, J. Rousset, H. Chehade, E. Ngoya, D. Barataud, and J. P. Teyssier, "The use of artificial neural networks in nonlinear microwave devices and circuits modeling: an application to telecommunication system design," *Int. J. RF and Microwave Computer-Aided Engineering*, vol. 9, no. 3, pp. 198-215, May 1999.
- [6] M. Lazaro, I. Santamaria, and C. Pantaleon, "NNs for large and small-signal modeling of MESFET/HEMT transistors," *IEEE Trans. on Circuits Measure*, vol. 50, no. 6, pp. 1587-1593, Dec. 2001.
- [7] S. Goasguen and S. M. El-Ghazaly, "A practical large - signal global modeling simulation of a microwave amplifier using artificial neural network," *IEEE Microwave and Guided Wave Letters*, vol. 10, no. 7, pp. 273-275, Jul. 2000.
- [8] P. H. da F. Silva, M. A. B. de Melo, and A. D. D. Neto, "Using neural network models for efficient GaAs MESFET time domain nonlinear circuit analysis," in *Proc. IJCNN*, vol. 3pp. 2282-2287, 2002.
- [9] J. W. Bandler, M. A. Ismail, J. E. Rayas - Sanchez, and Q. J. Zhang, "Neuromodeling of microwave circuits exploiting space - mapping technology," *IEEE Trans. Microw. Theory Tech.*, vol. 47, no. 12, pp. 2417-2427, Dec. 1999.
- [10] L. Zhang, J. Xu, M. C. E. Yagoub, R. T. Ding, and Q. J. Zhang, "Efficient analytical formulation and sensitivity analysis of neuro-space mapping for nonlinear microwave device modeling," *IEEE Trans. Microw. Theory Tech.*, vol. 53, no. 9, pp. 2752-2767, Sep. 2005.
- [11] M. Lundstrom, *Fundamentals of Carrier Transport*, 2nd ed., Cambridge University Press, 2000.
- [12] S. E. Hosseini and R. Faez, "Novel quantum hydrodynamic equations for semiconductor devices," *Jap. J. Appl. Phys.*, pt. 1, vol. 41, n. 3A, 1300-1304, 15 Mar. 2002.