

Д. ф.-м. н. Ю. М. ШВАРЦ, П. А. ЯГАНОВ, В. Г. ДЗЮБА

Украина, г. Киев, Институт физики полупроводников им. В. Е. Лашкарёва;
НТУУ "Киевский политехнический институт"
E-mail: shwarts.isp.kiev.ua

Дата поступления в редакцию
06.06 2005 г.
Оппонент к. т. н. А. О. ДРАНКОВА
(ОНИПУ, г. Одесса)

НЕЙРОСЕТЕВАЯ АППРОКСИМАЦИЯ ТЕРМОМЕТРИЧЕСКОЙ ХАРАКТЕРИСТИКИ ДИОДНОГО СЕНСОРА

Впервые предложен нейросетевой алгоритм обработки экспериментальных данных, что позволило повысить точность аппроксимации до 1,5 мК в диапазоне температур 4,2—357 К.

Для математического описания термометрических характеристик (ТМХ) широкодиапазонных диодных сенсоров температуры (ДСТ) используют полиномы Чебышева [1], сплайн-функции [2], комбинации сплайн-интерполяции и аппроксимации с использованием ортогональных полиномов Чебышева [3]. Предложенный в [4] метод многофакторного анализа позволяет получить высокоточную аппроксимацию ТМХ без учета требования постоянства прямого тока ДСТ. Все это свидетельствует о том, что совершенствование методов аппроксимации термометрических характеристик широкодиапазонных высокоточных термодиодных датчиков, удовлетворяющих основным критериям оптимальности, продолжается.

Актуальной задачей является поиск метода наилучшей аппроксимации для кремниевых ДСТ. Это обусловлено тем, что если описание ТМХ на высокотемпературном участке (130—500 К) методом степенных полиномов или полиномов Чебышева дает вполне удовлетворительный результат, то в области криогенных температур из-за особенностей экспериментальных ТМХ (обусловленных резким и немонотонным изменением температурной зависимости чувствительности) необходимо проводить аппроксимацию на отдельных участках. На границах этих участков неизбежно возникает снижение точности аппроксимации, которая не всегда может быть решена удовлетворительно. Критерием качества в этом случае служит дифференцируемость выбранного уравнения математической модели в области определения ТМХ. Использование для этих целей, например, ортогональных полиномов Чебышева, медленно сходящихся в широком диапазоне измеряемых диодным сенсором температур, приводит к излишне громоздкому полиному степени от 218 и выше.

В работе представлен нейросетевой метод аппроксимации ТМХ термодиодного сенсора, ранее не использовавшийся для решения подобных задач в термометрии. Также продолжено исследование возможностей полиномиальной аппроксимации методом регрессионного анализа, начатых в [4], и проведен сравнительный анализ этих методов.

Регрессионный анализ ТМХ

Традиционно представление ТМХ температурных сенсоров осуществляют степенным полиномом, порядок которого определяется требуемой точностью измерения физической величины. Наиболее распространенным способом определения коэффициентов полинома является метод наименьших квадратов, а матричная форма его реализации позволяет автоматизировать процесс с использованием ПЭВМ, так как подпрограммы матричной алгебры входят в пакет Microsoft Office.

Для моделирования ТМХ, устанавливающей связь между падением напряжения на $p-n$ -переходе U и температурой T при фиксированном рабочем токе, был использован метод регрессионного анализа [4], в соответствии с которым коэффициенты аппроксимирующего полинома вида $U = b_0 + b_1 T + b_2 T^2 + b_3 T^3 + b_4 T^4 + b_5 T^5 + b_6 T^6 + b_7 T^7 + b_8 T^8 + b_9 T^9 + b_{10} T^{10}$ были определены по результатам обработки экспериментальных измерений 59 пар значений T и U в исследованном диапазоне температур 4,2...357 К. Среднеквадратическое отклонение модели $\sigma_{\text{мод}}$ составило 60 мК.

В ряде практически важных случаев требуется повышение точности полиномиальной аппроксимации. Для этого может быть использована процедура ре-

Коэффициенты полиномиальной аппроксимации, рассчитанные методом регрессионного анализа и параметрической оптимизации

Регрессионный анализ		Параметрическая оптимизация			
Коэффициенты регрессии		Коэффициенты полинома		Показатели степени полинома	
b_0	3,318	U_0	-19,65152	—	—
b_1	-0,3008	A	-0,0309	a	1,0
b_2	0,01467	B	8541584,25	b	-4,49567
b_3	-0,000358	C	-88503,671	c	-1,20798
b_4	$5,015 \cdot 10^{-6}$	D	0,43966	d	0,64531
b_5	$-4,337 \cdot 10^{-8}$	E	431,53	e	-0,58492
b_6	$2,391 \cdot 10^{-10}$	F	-953181,3	f	-2,13114
b_7	$-8,419 \cdot 10^{-13}$	G	2483831,4	g	-2,60464
b_8	$1,831 \cdot 10^{-15}$	H	-3958842,6	h	-3,45349
b_9	$-2,242 \cdot 10^{-18}$	I	196360,52	i	-1,68071
b_{10}	$1,181 \cdot 10^{-21}$	J	-6357072,5	j	-4,5202
σ , мК	58,581	σ , мК	4,9	—	—

грессионного анализа для расчета коэффициентов целевой функции $U=U_0+AT^a+BT^b+CT^c+DT^d+ET^e+FT^f+GT^g+HT^h+IT^i+JT^j$, не превышающей степени регрессионного полинома, который рассматривался как базовое решение задачи, с последующей параметрической оптимизацией этих коэффициентов. Точность аппроксимации удалось повысить более чем на порядок.

Сравнительные результаты аппроксимации ТМХ указанными методами представлены в **таблице**.

Точность полученной полиномиальной аппроксимации достаточна для большинства практически востребованных задач. Она может быть повышена путем увеличения степени полинома, если в измерительной системе, где используется диодный сенсор, для сопряжения его с микроконтроллером нет ограничения на форму степенной аппроксимирующей ТМХ функции. Обычно желательно иметь аппроксимирующий полином не выше 10-го — 12-го порядка.

Нейросетевая аппроксимация

В основе работы нейросетевых алгоритмов аппроксимации экспериментальных данных положены результаты теоретических исследований А. Н. Колмогорова, В. А. Арнольда и Хехт-Нильсена. В их работах было показано, что любую функцию многих переменных можно представить (смоделировать) двухслойной нейронной сетью с прямыми связями с n нейронами входного слоя, $2n+1$ нейронами скрытого слоя, m нейронами выходного слоя и заранее заданными функциями активации f . Функции активации должны быть непрерывными и дифференцируемыми в области определения. Обычно это сигмоидальные функции, выходные значения которых монотонно меняются от 0 до 1 [5—7].

Функционирование искусственной нейронной сети имитирует работу коры головного мозга, где выработка управляющего сигнала происходит в результате параллельной обработки большого объема информации. В отличие от ЭВМ фон Неймана, производящих последовательные вычисления с огромной скоростью, нейронная сеть требует значительно меньших вычислительных ресурсов. К тому же она запоминает как правильный результат, так и ошибки, учитывая их в последующих вычислениях, и, следовательно, способна обучаться.

Для решения задачи в рамках данной работы была построена простая нейронная сеть с прямыми связями и одним скрытым слоем, архитектура которой представлена на **рис. 1**.




Рис. 1. Архитектура нейронной сети задачи аппроксимации термометрической характеристики диодного сенсора

Входной вектор температур X возбуждал входной нейрон 1, имеющий 20 связей через синаптические (весовые) коэффициенты связей a_j с 20 нейронами c_j скрытого слоя 2, каждый из которых обладал смещением. Выходы нейронов скрытого слоя b_j формировали выходной вектор напряжений Y выходного нейрона 3. Функция активации нейронов скрытого слоя f_1 — гиперболический тангенс, а выходного нейрона f_2 — линейная функция без смещения. Математическая модель данной нейронной сети представляется системой уравнений

$$\begin{cases} c_j = f_1(a_j X + a_j^0); \\ Y = f_2(\sum_{j=1}^{20} c_j b_j + b^0), \end{cases} \quad (1)$$

где a_j^0 , b^0 — начальное смещение нейронов скрытого слоя и выходного слоя, соответственно.

Прежде чем решать поставленную задачу, нейросеть должна быть предварительно обучена, т. к. после инициализации архитектуры сети, когда ее синаптические коэффициенты являются случайными числами, аппроксимация происходит с недостаточной точностью. В процессе обучения после ввода каждого значения входного аргумента выходное значение аппроксимируемой функции корректируется в зависимости от ошибки, допущенной сетью. Сеть реагирует на это изменением значений синаптических коэффициентов, и следующее входное значение обрабатывается так, что ошибка аппроксимации стабильно снижается.

Обучающая выборка должна быть репрезентативной, т. е. достаточной для достижения поставленной цели. Такая процедура обучения называется «обучением с учителем», когда нейросети предъявляются как входные данные по аргументу X , так и выходные — по аргументу Y . В данном случае входным аргументом X являлась температура, а выходными значениями функции Y — падение напряжения на диодном сенсоре температуры.

Подбор синаптических коэффициентов обычно осуществляется одним из градиентных методов. В описываемой сети этот подбор проводили на основе процедуры регуляризации по правилу Байеса, реализованной в составе пакета прикладных программ Matlab 6.0, 7.0 со встроенным критерием останова [8]. Процесс обучения составил 300 эпох (итераций), продолжавшихся 1,5 с. Был определен 61 весовой коэффициент нейросети, обеспечивший точность аппроксимации $\sigma \approx 1,5$ мК.

Для качественного моделирования нейронной сетью необходимо, перед тем как начинать процедуру обучения, произвести предварительное нормирование входных данных. Это обуславливается тем, что функция f_1 быстро входит в область насыщения при значительных отклонениях аргумента от среднего значения по множеству входных значений. Поэтому кодирование вектора входных значений проводилось так, чтобы их элементы оказались в интервале значений $[-1; +1]$. Для этого использовалась формула преобразования:

$$\tilde{X} = \frac{2(X - X_{\min})}{X_{\max} - X_{\min}} - 1,$$

где $\tilde{X}$ — кодированное значение элемента входного множества;
 X — значение элемента входного множества;
 $X_{\min}$ — значение минимального элемента входного множества;
 $X_{\max}$ — значение максимального элемента входного множества.

Множество выходных значений также нормировано, но уже самой сетью. Поэтому для восстановления переменных в натуральных показателях та же процедура была проведена и с множеством выходных значений, но теперь с целью декодирования.

Общее аппроксимационное выражение, полученное нейронной сетью, в соответствии с (1) содержит 21 слагаемое: суперпозицию 20 функций активации нейронов скрытого и выходного слоев и коэффициент начального смещения нейрона выходного слоя b^0 . Общее решение достаточно громоздко, поэтому ниже приведен фрагмент функции аппроксимации, включающий начальные и конечные слагаемые:

$$U = 0,91393 \tilde{Y} + 0,5767,$$

где $\tilde{Y} = 0,118 \cdot \text{th}(-9,5337 \tilde{X} + 10,506) + 0,0302 \times$
 $\times \text{th}(-10,198 \tilde{X} + 8,9351) - 0,01845 \cdot \text{th}(10,046 \tilde{X} - 8,0976) + \dots$
 $\dots - 6,911 \cdot \text{th}(26,127 \tilde{X} + 25,759);$

$$\tilde{X} = \frac{2(T - 4,229)}{352,887} - 1.$$

Обсуждение

Аппроксимация термометрической характеристики диодных сенсоров температуры различными способами показала, что выбор метода в значительной степени предопределяет результат. На **рис. 2** представлены экспериментальные ТМХ диодного сенсора, измеренные с точностью $\pm 0,023$ К при токе 1 мкА. На **рис. 3** приведены абсолютные отклонения ΔT экспериментально измеренной температуры от аппроксимируемого значения ТМХ, а на **рис. 4** показана зависимость среднеквадратического отклонения аппроксимации σ для ТМХ, найденные методом регрессионного анализа и нейросетевого алгоритма. Сравнительный анализ подтверждает высокую эффективность нейросетевой аппроксимации ТМХ, точность которой не менее чем в 3 раза выше точности полиномиальной аппроксимации. Достигнутая нейронной




Рис. 2. Экспериментальная термометрическая характеристика диодного сенсора температуры

сетью высокая точность аппроксимации ($\approx 1,5$ мК) в исследованном диапазоне температур 4,2—357 К позволяет впервые в диодной термометрии снять (или частично снять) проблемы других методов.

В современных измерительных системах для калибровки сенсоров широко используют микроконтроллеры. Технологический прогресс в области микроэлектроники почти каждые 18 месяцев удваивает вычислительные мощности микропроцессоров и микроЭВМ, а их цена стабильно снижается. Восемьразрядные процессоры Intel 8086 используют в микроЭВМ МК51, и, хотя отсутствие аналого-цифровых и цифроаналоговых преобразователей в их составе усложняет схемотехнику преобразования сигнала, рабочие частоты до 20 МГц и объем памяти до 20 Кбайт позволяют рассматривать их как эффективный инструмент обработки данных. С их помощью можно осуществить преобразование выходного сигнала измерительной системы, учесть ошибку измерения физической величины, произвести эффективную коррекцию сигнала во вторичном преобразователе или магистральном интерфейсе.

Основная задача, которая решается при помощи микроконтроллера, состоит в точной идентификации




Рис. 3. Погрешность аппроксимации термометрической характеристики диодного сенсора, полученной методом регрессионного анализа (1) и нейросетевого алгоритма (2)




Рис. 4. Среднеквадратическое отклонение аппроксимации σ термометрической характеристики сенсора, полученной методом регрессионного анализа (1) и нейросетевого алгоритма (2)

величины измеряемого параметра в процессе его воспроизведения. Для этого в программируемое запоминающее устройство (ПЗУ) микроконтроллера заносят калибровочные данные сенсора с шагом, соответствующим разрешающей способности измерительного преобразователя. Набор этих данных является уникальным для каждого датчика и используется затем в процессе кусочно-линейной аппроксимации выходной характеристики.

В настоящее время реализация нейросети возможна по одному из трех принципиально различных вариантов, выбор которого зависит от сложности и вычислительной стоимости решаемых задач.

Первый вариант предполагает программную реализацию на универсальных ЭВМ с традиционной архитектурой фон Неймана. (Пример такой реализации рассмотрен в данной работе.)

Второй вариант предусматривает наличие периферийного компьютерного устройства, например, специальной платы ввода информации в компьютер, при помощи которой выполняют некоторые нейровычислительные операции, а основные операции нелинейного преобразования происходят в центральном процессоре ЭВМ. Как правило, аппаратная часть устройства содержит программируемые логические интегральные схемы (ПЛИС), в составе которых имеются блоки ввода/вывода, конфигурируемые логические блоки и сети внутренних межсоединений. Эти однокристалльные интегральные микросхемы могут быть запрограммированы или перепрограммированы для реализации нейросетевых алгоритмов решения задач с физическим распараллеливанием на уровне микрочипа. Каждый блок ввода/вывода кодируют для выполнения функций элементов связующего интерфейса с внешней системой датчиков: конфигурируемые логические блоки — для выполнения логических операций, а скоростные межсоединения — для создания коммуникативных каналов информации. Необходимые для этого коды прописываются в адрес-

ном пространстве ПЛИС. Такая перестраиваемость конфигурации позволяет ПЛИС обеспечивать оперативность и непрерывность обработки информации, придавая ей качества сопроцессора ЭВМ [9].

Третий вариант состоит в том, что технологическими средствами современной микроэлектроники все элементы нейросети, за исключением некоторых блоков, реализуются системно в виде кристалла сверхбольшой интегральной схемы — СБИС-нейрочипа. С 1990-х годов разработкой и изготовлением СБИС-нейрочипов занимаются многие ведущие фирмы промышленно развитых стран мира [10, 11]. Нейрочипы выпускаются как с жесткой, так и с гибкой структурой, когда различные нейроалгоритмы записываются в ПЗУ. Отдельный класс СБИС-нейрочипов составляют проблемно-ориентированные, предназначенные для обработки, архивирования и выделения участков изображений, анализа видеопотока, распознавания образов и т. д.

Выводы

В работе впервые представлен алгоритм нейросетевой аппроксимации для расчета термометрической характеристики кремниевых диодных сенсоров. Проведен сравнительный анализ данных, полученных при расчете термометрических характеристик нейросетевым методом и традиционно используемым полиномиальным методом аппроксимации. Обоснована необходимость использования современных аппаратных возможностей и алгоритмических методов исследований, к числу которых принадлежат процессоры и нейросетевые алгоритмы. Способность нейронных сетей обучаться позволяет восстанавливать значение измеряемого параметра, не прибегая к дорогостоящей, а иногда и просто технически невозможной процедуре проверки калибровки сенсора. Обученная на соответствующем массиве информации нейросеть может «вспомнить» всю термометрическую характеристику по нескольким реперным точкам [12].

Параллельный процесс вычислений и гибкость архитектуры делает нейросети незаменимым инструментом обработки скоростных потоков информации в системах контроля и управления, для которого разработана программная и аппаратная поддержка. Нейросетевой алгоритм обладает потенциально более высокой точностью, скоростью обработки данных, совместимостью с современными компьютерными технологиями.

Дальнейшее развитие метода будет направлено на исследование возможностей создания интеллектуальной системы контроля состояния технических систем различной природы.

ИСПОЛЬЗОВАННЫЕ ИСТОЧНИКИ

1. Temperature measurement and control // In: Product Catalog and Reference Guide.— Westerville, OH (USA): Lake Shore Cryotronics, Inc., 2004.
2. Логвиненко С. П., Кононенко А. И., Левченко Е. П. и др. Аппроксимация в интервале 4,2÷300 К термометрических характеристик термодиодов из GaAs n-типа // Криогенная и вакуумная техника. (Харьков).— 1973.— Вып. 3.— С. 90—93.
3. Иващенко А. Н., Шварц Ю. М. Аппроксимация термометрических характеристик кремниевых диодных сенсоров температуры // Оптоэлектроника и полупроводниковая техника.— 2003.— Вып. 38.— С. 61—70.

4. Яганов П. О., Шварц Ю. М. Апроксимація термометричної характеристики діодних сенсорів методом багатфакторного аналізу // Вісник НТУУ „КПІ”. Сер. Приладобудування.— 2005.— № 30.— С. 5—11.
5. Круглов В. В., Борисов В. В. Искусственные нейронные сети. Теория и практика.— М.: Горячая линия-Телеком, 2002.
6. Комарцова Л. Г., Максимов А. В. Нейрокомпьютеры.— М.: Изд-во МГТУ им. Н. Э. Баумана, 2002.
7. Назаров А. В., Лоскутов А. И. Нейросетевые алгоритмы прогнозирования и оптимизации систем.— СПб: Наука и техника, 2003.
8. Медведев В. С., Потемкин В. Г. Нейронные сети. MATLAB 6 (Пакеты прикладных программ. Кн. 4).— М.: Диалог-МИФИ, 2002.
9. Борисов В. Л. Как правильно выбрать нейроускоритель? // VI Всерос. конф. «Нейрокомпьютеры и их применение».— Москва.— 2000.— С. 445—460.
10. Рогоза В. С., Ищенко А. В. Нейровычисления: состояние проблемы развития математического аппарата и аппаратного обеспечения // Электроника и связь.— 2004.— № 23.— С. 76—89.
11. Шевченко П. А., Фомин Д. В., Черников В. М., Вискне П. Е. Архитектура нейропроцессора NeuroMatrix NM 6403 // V Всерос. конф. «Нейрокомпьютеры и их применение».— Москва.— 1999.— С. 70—80.
12. Турченко В. А., Кочан В. В., Саченко А. А., Лаопулос Т. Улучшенный метод интеграции исторических данных с использованием нейронных сетей // Датчики и системы.— 2002.— № 7.— С. 35—38.

НОВЫЕ КНИГИ

НОВЫЕ КНИГИ

Фрайден Дж. Современные датчики. Справочник.— М.: Техносфера, 2005.— 592 с.

Даже первичное восприятие оглавления данного справочника оставляет в памяти чрезвычайно высокий уровень упорядочения и лаконичности представленного материала. Для студентов и аспирантов — это великолепное учебное пособие по современной сенсорике; для инженеров — справочная книга, позволяющая оптимизировать технические решения на современном уровне; для исследователей — монография, изложенная профессионалом высокого уровня, стимулирующая к поиску современных методов контроля и измерений параметров технических, биологических объектов и окружающей среды с использованием новых материалов, конструкций и технологий.

Щапова И. А. Частотный англо-русский словарь по оптоэлектронике.— М.: Флинта: Наука, 2005.— 15 л.

Словарь содержит около 4500 терминов по оптоэлектронике, лазерной технике, волоконной оптике и оптическим методам обработки информации. В структуру словаря входят: частотный словарь однословных терминов, частотный словарь терминологических словосочетаний, алфавитно-частотный словарь сокращений и условных обозначений.

Для научных работников, преподавателей, аспирантов, студентов вузов — факультетов оптоэлектроники, электроники, микроэлектроники, переводчиков научно-технической литературы, а также лингвистов, интересующихся проблемами терминологии



в портфеле редакции

- в портфеле редакции ➤ Газоанализаторы на основе пористого карбида кремния. (Россия, г. Таганрог)
- в портфеле редакции ➤ Низкотемпературная модификация медных пленок под воздействием атомарного водорода. (Украина, г. Запорожье)
- в портфеле редакции ➤ Компьютерное моделирование проводимости композитов с хаотической структурой. (Украина, г. Одесса)
- в портфеле редакции ➤ Пьезоэлектрический ионизатор воздуха с плавной регулировкой производительности. (Украина, г. Алчевск)
- в портфеле редакции ➤ Гальваномагнитные микродатчики на базе германиевого микропровода. (Молдова, г. Кишинёв)
- в портфеле редакции ➤ Кулеры на тепловых трубах для теплонагруженных компонентов ПК. (Украина, г. Киев)
- в портфеле редакции ➤ Исследование нестабильности спектрального распределения излучения ртутных ламп. (Украина, г. Черновцы)



в портфеле редакции