

Интернет-журнал «Наукоедение» ISSN 2223-5167 <http://naukovedenie.ru/>

Том 8, №3 (2016) <http://naukovedenie.ru/index.php?p=vol8-3>

URL статьи: <http://naukovedenie.ru/PDF/59TVN316.pdf>

Статья опубликована 14.06.2016.

Ссылка для цитирования этой статьи:

Хоанг Ван Чи, Сальников В.С. Нейросетевой подход к моделированию температурно-силовых характеристик процесса резания // Интернет-журнал «НАУКОВЕДЕНИЕ» Том 8, №3 (2016)

<http://naukovedenie.ru/PDF/59TVN316.pdf> (доступ свободный). Загл. с экрана. Яз. рус., англ.

УДК 621.91.02

Хоанг Ван Чи

ФГБОУ ВО «Тульский государственный университет», Россия, Тула

Аспирант

E-mail: Hoangchi.phd@gmail.com

Сальников Владимир Сергеевич

ФГБОУ ВО «Тульский государственный университет», Россия, Тула

Доктор технических наук, профессор

E-mail: tst@tsu.tula.ru

Нейросетевой подход к моделированию температурно-силовых характеристик процесса резания

Аннотация. В данной работе рассмотрен вопрос повышения эффективности металлообработки резанием. Проведен обзор литературы по вопросу применения искусственной нейронной сети в системах управления процессом механической обработки и, в частности в системах мониторинга состояния процесса резания. Предложена модель температурно-силовых характеристик процесса резания, построенная на искусственной нейронной сети и учитывающая управляющие и возмущающие воздействия. Разработан модифицированный алгоритм ее обучения, обеспечивающий сокращение времени и ошибки обучения при одном и том же размере обучающей выборки. Подробно описана методика моделирования температуры в зоне резания и силы резания с применением искусственной нейронной сети, обучающаяся на основе проведенных экспериментальных данных исследований температурно-силовых характеристик процесса резания. В результате сравнительных исследований доказана перспективность использования нейросетевого подхода к моделированию процесса резания в условиях неопределенности по сравнению с традиционными методами. Предложенную модель и алгоритм ее обучения целесообразно использовать в системах адаптивного управления процессом резания.

Ключевые слова: резание; моделирование; обучение; нейронная сеть

Введение

Проблема повышения эффективности металлообработки резанием была и остается одной из главных в машиностроении. Сложность ее решения связана с тем, что процесс резания характеризуется множеством взаимосвязанных факторов, влияющих как на ход процесса, так и на его результаты. Поэтому мониторинг и определение оптимальных режимов резания является актуальной технико-экономической задачей в области машиностроения. Значение этой задачи особенно возрастает в связи с широкой автоматизацией производства, применением станков с числовым программным управлением, автоматических станочных

линий и многооперационных станков, а также широким использованием новых материалов, как правило, обладающих низкой обрабатываемостью резанием.

Для оптимизации процессов резания с целью повышения качества продукции и снижения их себестоимости, обычно принимают метод условной оптимизации. Эффективность оптимизации как процедуры выбора оптимальных технологических условий резания требует высокого качества всех составляющих ее частей: адекватности физической и математической моделей реальному процессу, а также использования современных математических методов оптимизации. В связи с этим повышение качества используемых моделей является одной из актуальных задач повышения эффективности процесса резания.

Анализ состояния вопроса

Для решения поставленной проблемы широко используется подход, основанный на построении математических моделей, учитывающих различного рода неопределенности. Перспективным в этом направлении является применение искусственных нейронных сетей (ИНС). Создание модели процесса резания в виде ИНС дает возможность применить накопленный исследовательский опыт и известные эмпирические зависимости. Все существующие знания о процессе резания являются базой данных для обучения сети. Впоследствии на ее основе могут быть построены адаптивные модели управления и контроля процесса резания, осуществлен выбор оптимальных режимов резания и прогнозирование износа инструмента.

Одним из основных направлений применения нейронных сетей в задачах механической обработки является *моделирование процессов*. Так, J.F. Briceno, H. El-Mounaoui, S. Mukhopadhyay [1] использовали ИНС для эффективного моделирования процесса концевой фрезеровки, а D. Mandal, S.K. Pal и P. Saha [2] для моделирования процесса электроэрозионной обработки. В работе [3] осуществлено моделирование нелинейных, нестационарных погрешностей, вызванных тепловыми деформациями в станке. Известно также моделирование взаимосвязи режимов резания и параметров процесса при высокоскоростной обработке [4]. В качестве входных параметров этой ИНС были выбраны скорость резания, машинное время, подача, глубина резания и давление охлаждающей жидкости, а выходных: тангенциальная сила, осевая сила, потребляемая мощность двигателя шпинделя, шероховатость обработанной поверхности, средний износ по задней поверхности, максимальный износ по задней поверхности, износ при вершине лезвия.

ИНС нашли широкое применение и в системах *диагностики процессов* механической обработки. Например, H-Y Kim и J-H Ahn [5] в своих исследованиях провели мониторинг процесса удаления стружки при сверлении на основании данных по потребляемой мощности двигателя шпинделя. Нейросетевой подход применяется и в диагностике операций шлифования, а именно мониторинг сигналов акустической эмиссии и потребляемой мощности с целью выявления температурных перенапряжений [6]. M. Korosec, J. Balic, J. Корас [7] с помощью ИНС произвели оценку обрабатываемости свободных поверхностей заготовки по координатам точек, что позволило определить уровень сложности их обработки. P. G. Benardos, S. Mosialos, G.-C. Vosniakos [8] использовали ИНС для прогнозирования величины упругих деформаций заготовок от сил резания, возникающих в процессе точения. S. Arul, L. Vijayaraghavan, S.K. Malhotra [9] применили нейронную сеть для онлайн мониторинга качества заготовки при сверлении по сигналам акустической эмиссии, а также оценки влияния скорости резания и подачи на осевую силу и износ сверла по задней поверхности.

Известен целый ряд отечественных работ, посвященных мониторингу износа инструмента с применением искусственных нейронных сетей. В частности, предложены

системы контроля резцов при прецизионном точении, использующие техническое зрение [10], поддержания режущей способности инструмента [11], диагностики износа инструмента по звуковому сигналу [12].

Важным приложением нейронных сетей является их использование в системах *адаптивного управления процессов*. Большое внимание в этом направлении уделяется созданию ИНС, которые могли бы быть интегрированы в открытую архитектуру современных систем ЧПУ. John M. Fines и Arvin Agah [13] использовали ИНС для компенсации погрешности позиционирования в станках. ИНС применяются также для компенсации температурных погрешностей в обрабатывающем центре [14]. Известна ИНС с элементами нечеткой логики, использующая систему гипотетических умозаключений и сигналы о силе резания для оценки износа инструмента по задней поверхности при концевом фрезеровании [15].

Широко известно применение ИНС для *оптимизации режимов резания*. Предложен ряд алгоритмов оптимизации процессов точения, сверления, фрезерования и шлифования в условиях минимума исходных данных и ограниченного ресурса времени и [16]. R.K. Jain, V.K. Jain [17] предложили методику выбора оптимальных режимов для абразивно-струйной обработке, а Н. El-Mounaygi, Н. Kishawy и J. Vriceno [18] разработали интегрированную систему оптимизации сферического концевое фрезерования на станках с ЧПУ. Интересные результаты получены при использовании нейросетевого подхода для прогнозирования оптимальных зазоров в процессах листовой штамповки [19], а также для определения оптимальной формы стружколомающей канавки, обеспечивающей повышение производительности точения [20].

Известно большое количество работ, использующих ИНС в задачах *управления параметрами качества*, в частности прогнозирования шероховатости обработанной поверхности: [21–25] – при точении, [26–28] – при фрезеровании, [29, 30] – при сверлении, или при управлении качеством изделий массового производства [31, 32].

Доказано эффективное использование ИНС в системах диагностики качества поверхностного слоя непосредственно в процессе обработки на станках с ЧПУ [21], в условиях минимального использования СОТС [22], в процессе чистового точения закаленных деталей [23]. Использование ИНС наряду с теорией нечетких множеств позволило прогнозировать переменные параметры процесса по заданной шероховатости [24]. ИНС позволили систематизировать и обобщить результаты экспериментальных исследований влияния параметров твердосплавных пластин (без покрытия и покрытых методами PVD и CVD) на шероховатость поверхности при точении [25]. Для процессов сверления на основе данных о силе резания произведено оценивание шероховатости поверхности в композитном материале [30], а также прогнозирование микронеровностей поверхности из малоуглеродистых сталей [29].

Проведенный анализ подтвердил перспективность использования ИНС для моделирования и диагностики показателей, оптимизации и адаптивного управления процессом резания по данным датчиков, установленных в технологической системе. Доказана целесообразность использования в качестве контролируемых параметров температуры и силы резания, параметров вибрации и акустической эмиссии, тока и мощности, потребляемой электродвигателями главного движения, колебаний скорости вращения шпинделя.

Несмотря на достигнутые успехи, недостатком существующих работ в данной области является отсутствие единого подхода к выбору структуры и параметров ИНС, алгоритму ее обучения.

Моделирование процесса резания с применением ИНС

Выбор топологии и настройка весов связей ИНС являются одними из важнейших этапов при использовании нейросетевых технологий для решения практических задач. От этого этапа напрямую зависит качество (адекватность) полученных моделей и систем управления.

Топология нейронной сети определяется типом решаемой задачи и набором исходных данных. В данной работе рассмотрен вопрос оптимизации режимов резания на основе мониторинга его параметров. ИНС применяется как инструмент моделирования процесса. Согласно результатам анализа основных типов ИНС, проведенного D.E. Dimla [33], для решения поставленной задачи предложено использовать ИНС в виде многослойного персептрона с одним скрытым слоем.

Как уже отмечалось выше среди наиболее информативных параметров, характеризующих условия резания, следует выделить температуру и силу резания. Они наиболее доступные для оперативного измерения.

На сегодняшний день существует ряд работ, посвященных моделированию силы и температуры резания. Среди отечественных ученых этим вопросом занимаются С.С. Силин, А.Н. Резников, Н.Н. Зорев, А.М. Даниэтан; среди зарубежных – E. Loewen, M. Shaw, J. Jaeger, D. Weiner, F. Ling, E. Saibel, K.P. Monroy Vazquez, C. Giardini, E. Ceretti, и др.

В результате известных исследований получен большой объем экспериментальных данных, которые определяют эмпирические зависимости температуры и силы резания от различных параметров, характеризующих условий обработки. В частности, математические модели температуры резания С.С. Силина, А.Н. Резникова и А.М. Даниеляна соответственно [34-36], указывают на отсутствие единого подхода к выбору исходных данных:

$$\theta_p = 138 \cdot V^{0.36} \cdot S^{0.133} \cdot t^{0.09}, ^\circ\text{C} \quad (1)$$

$$\theta_p = 572.35 \cdot V^{0.397} \cdot S^{0.219} \cdot t^{0.06} \cdot \lambda^{-1.09} \cdot r^{-0.11} \cdot \varphi^{0.376}, ^\circ\text{C} \quad (2)$$

$$\theta_p = \frac{167 \cdot V^{0.4} \cdot S^{0.24} \cdot t^{0.105} \cdot (\sin \varphi)^{0.26}}{k^{0.086} r^{0.11} F^{0.056}}, ^\circ\text{C} \quad (3)$$

где: V – скорость резания, м/мин; S – подача, мм/обр.; t – глубина резания, мм; λ_0 – теплопроводность обрабатываемого материала, кал/(см·с·°C); r – радиус при вершине

инструмента, мм; φ – главный угол в плане инструмента, град.; $k = \frac{t}{S}$; F – площадь поперечного сечения резца, мм².

Математические модели силы резания С.С. Силина и Karla P. Monroy соответственно [34, 37] так же подтверждают это:

$$P_z = 2000 \cdot V^{-0.12} \cdot S^{0.95} \cdot t^{0.3}, \text{H} \quad (4)$$

$$P_z = (A_z + K_z \cdot E) \cdot V^{-0.15} \cdot S^{0.75} \cdot t^{0.6}, \text{H} \quad (5)$$

где: A_z и K_z – обобщенные коэффициенты, характеризующие условия обработки; E – термоЭДС в зоне резания, мВ.

Известен ряд работ, в которых ИНС используются для моделирования силы и температуры в зоне резания [38-43]. Они отличаются друг от друга видом и количеством входных параметров и используемыми алгоритмами обучения. Например, для прогнозирования трех составляющих силы резания в процессе концевой сферической фрезерования, U. Zuperl, F. Cus, V. Mursec и T. Ploj использовали ИНС с 5-ю входами: режим резания (V , S , t), прочность обрабатываемого материала и радиус при вершине инструмента [38]. Для моделирования температуры на границе контакта инструмента со стружкой в процессе токарной обработки предложено использовать ИНС с 4-я входами: режим резания и сила резания [41]. В рассмотренных работах, ИНС имеют только один выход: температура или сила резания. В этом случае набор входных параметров производится по известной методике [44]. Она базируется на соответствующих данных знаниях в предметной области и стандартных статистических критериях. Сложность взаимной связи нейронов в ИНС препятствует прямой статистической оценке важности входных параметров. Поэтому сначала включают все переменные, которые могут повлиять на результат, а затем поочередно сокращают их количество, удаляя одну из входных переменных и сравнивая точность нейронной сети до и после удаления. Программные средства моделирования ИНС (например, Propagator компании ARD Corporation, STATISTICA Neural Networks компании StatSoft и др.) позволяют распознавать значимые входные переменные и экспериментировать с их различными комбинациями.

Для моделирования нескольких параметров, например силы и температуры резания, предложено использовать ИНС с большим количеством входов (12): режим резания (V , S , t), геометрические характеристики инструмента (главный, передний и задний углы), механические характеристики обрабатываемого и инструментального материалов (температуропроводность, прочность, твердость) [42]. Однако применение такого подхода в реальном управлении сталкивается с определенными трудностями, связанными, в частности, с большим числом параметров входящих в нее в неявном виде и требующих оперативной идентификации.

Rastee D. Койе и др. в Германии в 2015 г. [43] предложили подход к оптимизации режимов резания, основанный на минимизации отклонений измеренных от расчетных значений температуры, силы и толщина стружки. В данной работе, использована ИНС с 8 входами: режим резания (скорость, подача), коэффициент термического расширения, коэффициент трения между двумя поверхности контакта, коэффициент трения вдоль плоскости сдвига, коэффициент пластинной деформации, коэффициент снижения первоначального напряжения течения, значения критерия разрушения Кокрофта-Латама. К недостаткам подхода следует отнести: отсутствие учета геометрических параметров инструмента; такие входные параметры, как критерий разрушения Кокрофта-Латама и коэффициент термического расширения, определяются косвенным способом; толщина стружки является неконтролируемым оперативными средствами параметром, что усложняет создание базы данных по нему для обучения ИНС. Это приводит к существенному усложнению модели, увеличению трудоемкости создания и объема базы экспериментальных данных, необходимых для обучения ИНС, что делает малоперспективным применение данного подхода при оперативном управлении.

Результат проведенного анализа показали, что режимы резания, механические характеристики обрабатываемого и инструментального материала, а также геометрические характеристики инструмента влияют на температуру и силу резания в разной степени. Степень влияния управляющих параметров на контролируемые параметры определяется коэффициентами чувствительности. Анализ выражений (1)...(5) и сравнительная оценка коэффициентов чувствительности, в частности температуры и силы резания, к параметрам, характеризующим условия обработки, позволили выделить следующие: подача, скорость и

глубина резания, теплопроводность обрабатываемого материала, главный угол в плане и радиус закругления вершины резца [34, 35, 45]. Причем глубину резания и радиус при вершине резца, с точки зрения управления предложено рассматривать как возмущениям. Они не поддаются оперативному контролю в процессе обработки, а их изменение приводит к нарушению заданных условий резания. При таком подходе ИНС позволяет однозначно определить, какое из возмущений вызывало отклонение выходных параметров.

На основании вышесказанного, для моделирования температурно-силовых параметров процесса резания предложено использовать ИНС в виде многослойного персептрона с одним скрытым слоем, с размерностью выходного слоя (число нейронов на выходе) равной числу контролируемых параметров - температура и сила резания; размерностью входного слоя (число нейронов на входе) равной шести, что соответствует числу наиболее значимых параметров, характеризующих условия резания ($V, S, t, \varphi, r, \lambda_\theta$) (см. рис. 1).

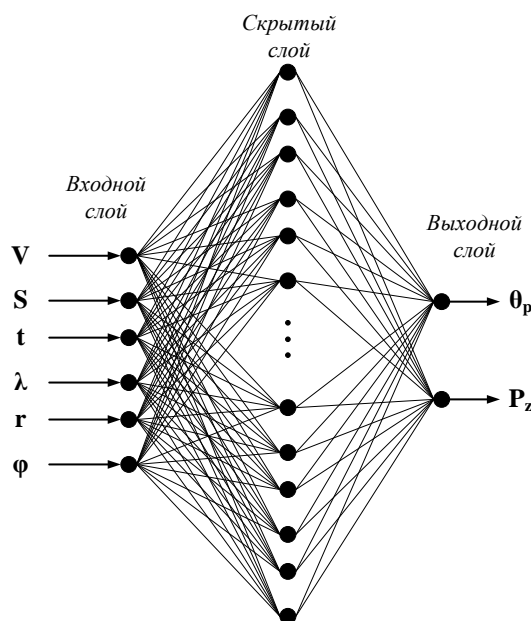


Рисунок 1. Структура ИНС (рисунок автора)

Для завершения структурной идентификации ИНС необходимо задать число нейронов в скрытом слое и характер связей между нейронами, то есть функции активации. При определении этого числа рекомендуется исходить из того, что, с одной стороны, способности сети к обобщению тем выше, чем больше суммарное число связей между нейронами. С другой стороны, число связей определяет минимально допустимый размер выборки обучающих данных [46]:

$$\frac{N_v \cdot N_c}{1 + \log_2 N_v} \leq N_h \cdot (N + N_c) \leq N_c \cdot \left(\frac{N_v}{N} + 1\right) \cdot (N + N_c + 1) + N_c \quad (6)$$

Где: N – размерность входного слоя; N_h – размерность скрытого слоя; N_c – размерность выходного слоя; N_v – размер обучающей выборки.

Для рассматриваемой задачи $N = 6, N_c = 2$

$$\frac{N_v}{4 + 4 \log_2 N_v} \leq N_h \leq \frac{3N_v}{8} + \frac{5}{2} \quad (7)$$

Например, для обучающей выборки равной 100 число нейронов в скрытом слое лежит в диапазоне $12 \leq N_h \leq 38$.

Выходной сигнал нейрона связан со входными сигналами через функции активации [44]:

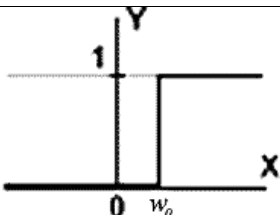
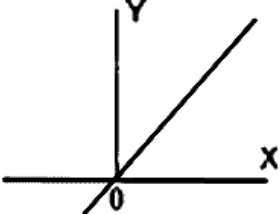
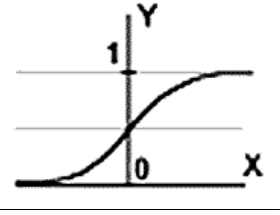
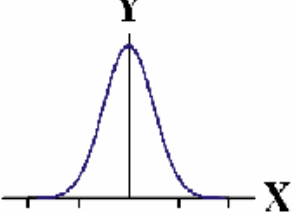
$$y = f(s); \quad s = \sum_{i=1}^n w_i x_i + b \quad (8)$$

где: w – вес связи, $i = 1..n$; b – значение смещения; s – значение суммы; x – компонент входного вектора (входной сигнал); y – выходной сигнал; n – число входов нейрона или число нейронов в предыдущем слое; f – функция активации.

В настоящее время не существует однозначного правила выбора вида функции активации. В зависимости от области исследований рекомендуются следующие 4 основные ее вида (см. табл. 1) [44].

Таблица 1

Основные виды функции активации для ИНС

№ п/п	Функция активации	Формула	Вид	Область применения
1	Единичного скачка	$f(x) = \begin{cases} 0, & x < \tau; \\ 1, & x \geq \tau. \end{cases}$		Распознавания
2	Линейная	$f(x) = x$		Прогнозирование и моделирование
3	Сигмоидная	$f(x) = \frac{1}{1 + e^{-ax}}$		
4	Гаусса	$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{(x-m)^2}{2\sigma^2}}$		Классификация

Как правило, при решении задач прогнозирования или моделирования для выходного слоя ИНС типа многослойного персептрона используется линейная функция, для скрытого слоя – сигмоидная [44].

В соответствии с этими рекомендациями при решении задачи моделирования процесса резания для скрытого и выходного слоев выбраны типовые структуры вида [1, 4, 7, 37, 44, 46, 47, 48.]:

$$f_1(s_1) = \frac{1}{1 + \exp(-s_1)}; f_2(s_2) = s_2 \quad (9)$$

где $f_1(s_1)$ и $f_2(s_2)$ – функции активации соответственно скрытого и выходного слоев.

Качество модели, использующей ИНС, определяется временем обучения и средней квадратичной погрешностью (Mean square error) выходных значений сети по отношению к желаемым их значениям. Метод и алгоритм обучения играют важную роль для повышения качества нейронной сети, то есть снижения времени обучения и величины погрешности [41].

В технических задачах наиболее широкое распространение получил алгоритм обучения с учителем и обратным распространением ошибки (Michael T. Manry и др.). Это итеративный градиентный алгоритм обучения, который используют с целью минимизации среднего квадратичного отклонения текущих выходов от требуемых значений [41].

Одним из современных перспективных алгоритмов обучения является алгоритм оптимизации весов скрытого и выходного слоев нейронной сети [48]. В ходе обучения после передачи многомерного входного вектора $X = [x_1, x_2, \dots, x_N]$ в многослойную нейронную сеть вычисляют соответствующие кросскорреляционные и автокорреляционные функции. После чего для минимизации средней квадратичной ошибки на основе решения системы уравнений для антиградиента определяют веса скрытого и выходного слоев [48].


К сожалению, данный алгоритм не гарантирует уменьшения ошибки с каждым шагом обучения. Это приводит к увеличению времени обучения.

Для обеспечения гарантии сходимости и ускорения процесса обучения ИНС предложено оптимизацию весов скрытого и выходного слоев производить с учетом направления их изменения в скрытом слое в случае увеличения ошибки [49].


В предложенном алгоритме обучения [49] после передачи многомерный входной вектор $X = [x_1, x_2, \dots, x_N]$ в многослойную нейронную сеть также вычисляют соответствующие кросскорреляционные и автокорреляционные функции. Далее на основе решения системы уравнений антиградиента определяют веса скрытого и выходного слоев. Дополнительно производят выбор направления изменения весов скрытого слоя путем последовательного назначения пары ближайших значений текущего веса $w_1(j, k) = w(j, k) - \xi$ и $w_2(j, k) = w(j, k) + \xi$, где $0 < \xi \leq 0,001$, и сравнения соответствующих им изменений средней квадратичной ошибки $\Delta E_1 = E_1 - E_{i-1}$ и $\Delta E_2 = E_2 - E_{i-1}$, где E_1, E_2 – значения средней квадратичной ошибки, соответствующие весам скрытого слоя $w_1(j, k)$ и $w_2(j, k)$, E_{i-1} – значение средней квадратичной ошибки предыдущего опыта. Если $\Delta E_1 < \Delta E_2$, то веса скрытого слоя изменяют в направлении уменьшения, если $\Delta E_1 \geq \Delta E_2$, то - в направлении увеличения.

Имитационное моделирование предложенного алгоритма обучения ИНС по экспериментальным данным С.С. Силина, А.Н. Резникова и А.М. Даниеляна соответственно [34-36], подтвердило его высокую эффективность. Результаты его сравнительной оценки с

оригинальным алгоритмом оптимизации весов скрытого и выходного слоев ИНС (Michael T. Manгу и др.) приведены на рис. 2. Из рисунка видно, что при равном числе нейронов в скрытом слое время обучения снижено более, чем в 2 раза, а величина ошибки уменьшена с 1,25% до 0,6%. Проведенные расчеты показали, что для получения результатов с погрешностью, не превышающей 0,6-1%, необходимо и достаточно, чтобы в скрытом слое ИНС число нейронов не превышало 20. При сохранении исходной погрешности этот алгоритм дает возможность уменьшить количество опытов для обучения модели, увеличивая, таким образом, оперативность идентификации условий резания.



а)



б)

Рисунок 2. Сравнительная оценка алгоритмов обучения: а) Среднеквадратичная ошибка; б) Время обучения (рисунок автора)

Экспериментальные исследования

Несмотря на огромный объем существующих экспериментальных данных, невозможно выбрать полноценную базу данных для моделирования температуры и силы резания в одинаковых условиях обработки. С целью расширения этой базы для обучения ИНС, проверки эффективности алгоритма обучения и адекватности модели проведены экспериментальные исследования при следующих условиях:

- Обрабатываемый материал: сталь марки **52100** (аналога стали **ШХ15**);

- Способ обработки: точение;
- Станок: токарный **Emco Concept Turn 250**;
- Заготовка: гладкий вал диаметра $D = 30 \text{ мм}$, длиной $L = 50..100 \text{ мм}$;
- Режущий инструмент: резец из твердого сплава **CBN010** (аналога сплава **T14K8**) (главный угол в плане $\varphi = 55^\circ$, передний угол $\gamma = 0^\circ$, задний угол $\alpha = 12^\circ$, радиус закругления $r = 3 \text{ мм}$);
- Диапазон варьируемых параметров: $V = 50..250 \text{ м/мин}$; $S = 0,25..1 \text{ мм/обр.}$; $t = 1..5 \text{ мм}$;
- Число опытов: для ИНС с 20-ю нейронами в скрытом слое в соответствии с (7) и допустимой ошибкой обучения 0,6-1% оптимальный размер выборки составляет $N_v = 64$ [50].

Обсуждение результатов моделирования

Основное требование, которое предъявляется к моделям это адекватность. Для проверки адекватности разработанной модели проведено ее сравнение с полученными экспериментальными данными и эмпирическими моделями А.Н. Резникова для температуры (2) и С.С. Силина для силы резания (4) [34, 35].

Предложенная модель процесса резания в виде многослойного персептрона с числом нейронов на входе равным 6, на выходе - 2 и одним скрытым слоем, содержащим 20 нейронов, после 20 шагов обучения сети по разработанному алгоритму позволила получить среднее значение ошибки, не превышающее 0,5%.

Результаты сравнительной оценки моделей представлены в рис. 3:

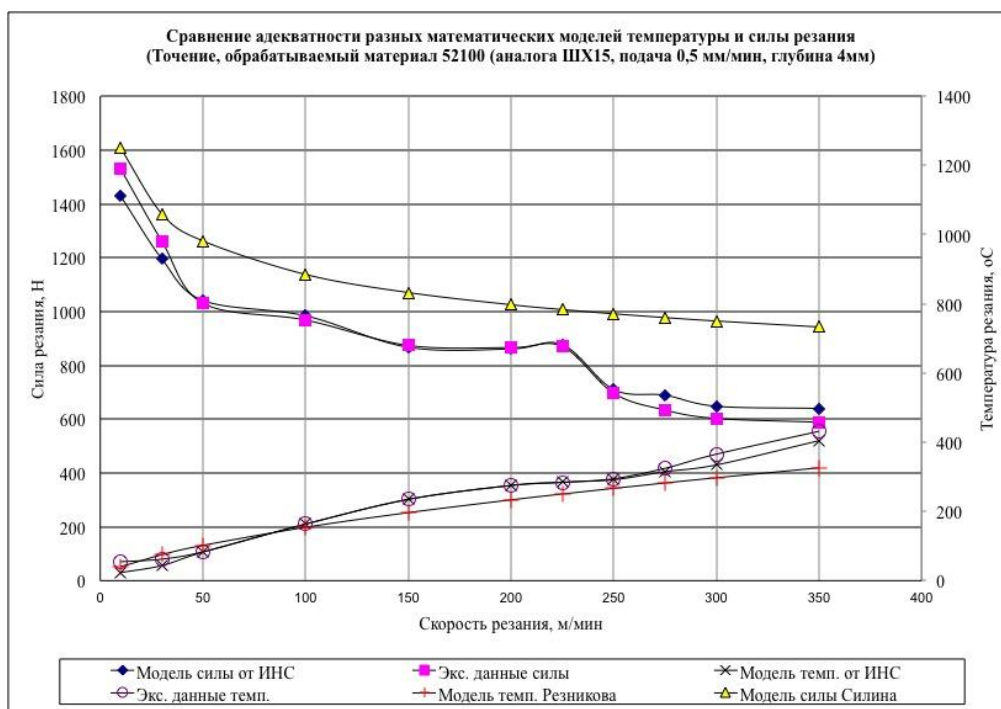


Рисунок 3 Сравнительная оценка моделей температурно-силовых характеристик процесса резания (рисунок автора)

Анализ полученных данных показывает, что максимальное значение средней квадратичной ошибки для ИНС не превышает 1%. Эмпирические зависимости (2) и (4) не отражают нарушение монотонности функций, связанной, в частности, с изменением характера стружкообразования [51, 52]. Величина ошибки для рассмотренных условий эксперимента для них достигает 10...20%.

Основным недостатком известных эмпирических зависимостей, в том числе построенных с помощью регрессионного анализа, является необходимость построения по сути новой модели при изменении условий обработки: режимов и объекта обработки, внешних возмущений. Проведение дополнительной серии экспериментов влечет дополнительные потери времени. Для нейронной сети в этих условиях тоже требуется проводить переобучение. Однако объем выборки зависит от степени изменения условий обработки, то есть от количества изменившихся входных параметров и диапазона их изменения. Важно, что этот объем может корректироваться в процессе обучения. Влияние объема выборки для переобучения ИНС на среднеквадратичную ошибку при изменении 1-го, 2-х и 3-х параметров приведено на рис. 4.

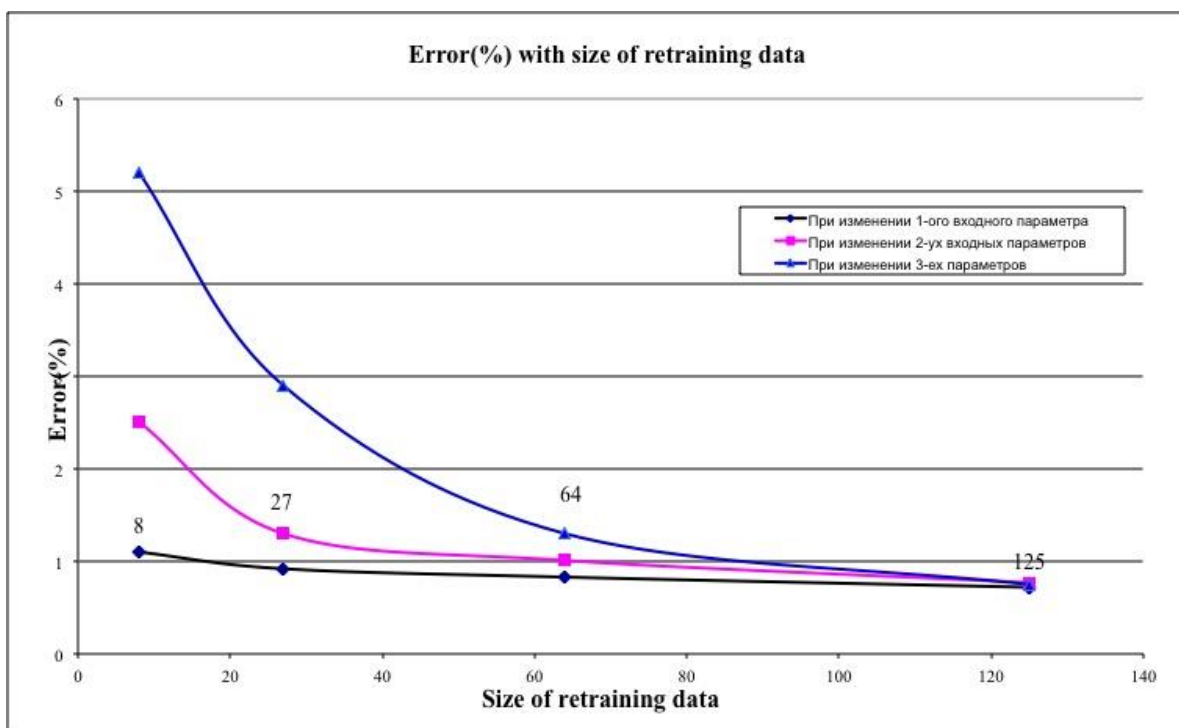


Рисунок 4. Влияние объема переобучающих данных на ошибку обучения при изменении 1-го, 2-х и 3-х параметров (рисунок автора)

Полученные результаты показывают, что при изменении только одного параметра для успешного переобучения ИНС достаточно провести только 8 экспериментов, чтобы скорректированная модель воспроизводила выходной сигнал с погрешностью не более 1,5%. При этом время переобучения нейронной сети составляет 50 секунд. Увеличение числа изменившихся параметров, например до 2-х или 3-х, при сохранении заданной точности приводит к необходимости увеличения объема выборки до 27 и 64 экспериментов соответственно. Это подтверждает высокую гибкость моделирования и переобучения таких моделей.

Основные выводы:

1. На основе проведенных исследований для моделирования температурно-силовых характеристик процесса резания предложена ИНС в виде многослойного перцептрон, имеющего один скрытый слой с 20 нейронами, входной слой с 6-ю нейронами (скорость подача, глубина резания, теплопроводность обрабатываемого материала, главный угол в плане и радиус при вершине резца) и выходной слой с 2-мя нейронами. Она обеспечивает воспроизведение выходных сигналов с погрешностью не более 1,5%.
2. Для оптимизации весов выходного и скрытых слоев предложен модифицированный алгоритм обучения с выбором направления изменения весов при изменении среднеквадратичной ошибки в процесс обучения. Он позволяет повысить точность и сократить время обучения.
3. Предложенную модель и алгоритм ее обучения целесообразно использовать в системах адаптивного управления процессом резания, поскольку они позволяют оперативно восстанавливать неконтролируемые возмущающие воздействия: теплопроводность обрабатываемого материала, главный угол в плане и радиус при вершине резца. Вследствие чего принимаются адекватные решения об изменении режимов резания.

ЛИТЕРАТУРА

1. Briceno J.F. Selecting an artificial neural network for efficient modeling and accurate simulation of the milling process / J.F. Briceno, H. El-Mounayri, S. Mukhopadhyay // *International Journal of Machine Tools and Manufacture*. – 2002. – Vol. 42, №6. - P. 663-674.
2. Mandal D. Modeling of electrical discharge machining process using back propagation neural network and multi-objective optimization using non-dominating sorting genetic algorithm-II / D. Mandal, S.K. Pal, P. Saha // *Journal of Materials Processing Technology*. – 2007. – Vol. 186, №1-3. – P. 154-162.
3. Yang H. Dynamic neural network modeling for nonlinear, nonstationary machine tool thermally induced error / H. Yang, J. Ni // *International Journal of Machine Tools and Manufacture*. – 2005. – Vol. 45, №4-5. – P. 455-465.
4. Modelling the correlation between cutting and process parameters in high-speed machining of Inconel 718 alloy using an artificial neural network / E.O. Ezugwu, D.A. Fadare, J. Bonney, R.B. Da Silva, W.F. Sales // *International Journal of Machine Tools and Manufacture*. – 2005. – Vol. 45, №12-13. – P. 1375-1385.
5. Kim H.-Y. Chip disposal state monitoring in drilling using neural network based spindle motor power sensing / H.-Y. Kim, J.-H. Ahn // *International Journal of Machine Tools and Manufacture*. – 2002. – Vol. 42, №10. – P. 1113-1119.
6. Kwak J.-S. Neural network approach for diagnosis of grinding operation by acoustic emission and power signals / J.-S. Kwak, M.-K. Ha // *Journal of Materials Processing Technology*. – 2004. – Vol. 147, №1. – P. 65-71.
7. Korosec M. Neural network based manufacturability evaluation of free form machining / M. Korosec, J. Balic, J. Kopac // *International Journal of Machine Tools and Manufacture*. – 2005. – Vol. 45, №1. – P. 13-20.

8. Benardos P.G. Prediction of workpiece elastic deflections under cutting forces in turning / P.G. Benardos, S. Mosialos, G.-C. Vosniakos // *Robotics and Computer-Integrated Manufacturing*. – 2006. – Vol. 22, №5-6. – P. 505-514.
9. Arul S. Online monitoring of acoustic emission for quality control in drilling of polymeric composites / S. Arul, L. Vijayaraghavan, S.K. Malhotra // *Journal of Materials Processing Technology*. – 2007. – Vol. 185, №1-3. – P. 184-190.
10. Система контроля и методы распознавания состояний резцов для поддержания их работоспособности / А.Г. Дерев'янченко, Л.В. Бовнегра, Д.А. Криницын, Е.В. Косс, А.А. Фомин // *Наукові праці ДонНТУ. Проектування прогресивних конструкцій різальних інструментів та технологічного оснащення*. – 2009. – С. 87–94.
11. Дерев'янченко О.Г. Використання засобів штучного інтелекту при створенні системи підтримки працездатності ріжучих інструментів / О.Г. Дерев'янченко, Р.Г. Доліщинський, Д.О. Криницин // *Вісник ЖДТУ. Технічні науки*. – 2009. – №3 (50). – С. 32–38.
12. Внуков Ю.Н. Моделирование износа инструмента по результатам вейвлет-преобразования звукового сигнала / Ю.Н. Внуков, В.И. Дубровин, Ю.С. Афонин, Т.В. Манило // *Штучний інтелект*. – 2008. – №1. – С. 73–79.
13. Fines J.M. Machine tool positioning error compensation using artificial neural networks / J.M. Fines, A. Agah // *Engineering Applications of Artificial Intelligence*. – 2008. – Vol. 21, №7. – P. 1013-1026.
14. Mize C.D. Neural network thermal error compensation of a machining center / C.D. Mize, J.C. Ziegert // *Precision Engineering*. – 2000. – Vol. 24, №4. – P. 338-346.
15. Uros Z. Adaptive network based inference system for estimation of flank wear in endmilling / Z. Uros, C. Franc, K. Edi // *Journal of Materials Processing Technology*. – 2009. – Vol. 209, №3. – P. 1504-1511.
16. Cus F. Approach to optimization of cutting conditions by using artificial neural networks / F. Cus, U. Zuperl // *Journal of Materials Processing Technology*. – 2006. – Vol. 173, №3. – P. 281-290.
17. Jain R.K. Optimum selection of machining conditions in abrasive flow machining using neural network / R.K. Jain, V.K. Jain // *Journal of Materials Processing Technology*. – 2000. – Vol. 108, №1. – P. 62-67.
18. El-Mounayri H. Optimization of CNC ball end milling: a neural network-based model / H. El-Mounayri, H. Kishawy, J. Briceno // *Journal of Materials Processing Technology*. – 2005. – Vol. 166, №1. – P. 50-62.
19. Hambli R. Application of a neural network for optimum clearance prediction in sheet metal blanking processes / R. Hambli, F. Guerin // *Finite Elements in Analysis and Design*. – 2003. – Vol. 39, №11. – P. 1039-1052.
20. Kim H.-G. Performance evaluation of chip breaker utilizing neural network / H.-G. Kim, J.-H. Sim, H.-J. Kweon // *Journal of Materials Processing Technology*. – 2009. – Vol. 209, №2. – P. 647-656.
21. Медведев В.В. Особенности диагностики качества механообработки с применением интеллектуальных систем / В.В. Медведев, В.С. Медведев //

- Вісник Донбаської державної машинобудівної академії. – 2008, №3Е (14). – С. 131–135.
22. Tsao C.C. Tool wear and surface roughness prediction using an artificial neural network (ANN) in turning steel under minimum quantity lubrication (MQL) / C.C. Tsao, H. Hochen // *Engineering and Technology*. – 2010. – №62. – P. 830-839.
 23. Ozel T. Predictive modeling of surface roughness and tool wear in hard turning using regression and neural networks / T. Ozel, Y. Karpat // *International Journal of Machine Tools and Manufacture*. – 2005. – Vol. 45, №4-5. – P. 467-479.
 24. Abburi N.R. A knowledge-based system for the prediction of surface roughness in turning process / N.R. Abburi, U.S. Dixit // *Robotics and Computer-Integrated Manufacturing*. – 2006. – Vol. 22. – №4. – P. 363-372.
 25. The experimental investigation of the effects of uncoated, PVD - and CVD-coated cemented carbide inserts and cutting parameters on surface roughness in CNC turning and its prediction using artificial neural networks / M. Nalbant, H. Gokkaya, I. Toktas, G. Sur // *Robotics and Computer-Integrated Manufacturing*. – 2009. – Vol. 25, №1. – P. 211-223.
 26. Oktem H. Prediction of minimum surface roughness in end milling mold parts using neural network and genetic algorithm / H. Oktem, T. Erzurumlu, F. Erzincanli // *Materials & Design*. – 2006. – Vol. 27, №9. – P. 735-744.
 27. Zain A.M. Prediction of surface roughness in the end milling machining using Artificial Neural Network / A.M. Zain, H. Haron, S. Sharif // *Expert Systems with Applications*. – 2010. – Vol. 37, №2. – P. 1755-1768.
 28. El-Sonbaty I.A. Prediction of surface roughness profiles for milled surfaces using an artificial neural network and fractal geometry approach / I.A. El-Sonbaty, U.A. Khashaba, A.I. Selmy, A.I. Ali // *Journal of Materials Processing Technology*. – 2008. – Vol. 200, №1-3. – P. 271-278.
 29. Panda S.S. Simultaneous prediction of surface roughness and drill flank wear in drilling a mild steel work piece using ANN, National Conference on Quality, Reliability and Maintainability aspect in Engineering systems. – 2007.
 30. Tsao C.C. Evaluation of thrust force and surface roughness in drilling composite material using Taguchi analysis and neural network / C.C. Tsao, H. Hocheng // *Journal of Materials Processing Technology*. – 2008. – Vol. 203, №1-3. – P. 342-348.
 31. S.T. A. Niaki and M. Davoodi, Designing a multivariate-multistage quality control system using artificial neural networks, *International journal of production research: American Institute of Industrial Engineers; Society of Manufacturing Engineers*. - London: Taylor & Francis, ISSN 0020-7543, ZDB-ID 1604776. - Vol. 47.2009, 1 (1.1.), p. 251-271.
 32. Cory Runyon Real-time quality control of the injection molding process using artificial neural networks / Thesis (M.S.)-Brigham Young University. Dept. of Manufacturing Engineering and Engineering Technology. Includes bibliographical references (leaves [82]-84).
 33. D.E. Dimla jr, P.M. Lister and N.J. Leighton, neural network solutions to the tool condition monitoring problem in metal cuttng-a critical review of methods. *Int. L Mich. Tools Mlumfla: t. Vol. 37. No. 9. pp. 1219-1241. 1997.*

34. Силин, С.С. Метод подобия при резании материалов Текст. М.: Машиностроение, 1979. - 152 с.
35. Резников А.Н. 1981 Теплофизика процессов механической обработки материалов.
36. Якобс Г.Ю., Якоб Э., Кохан Д., Даниэлян А.М. Теплота и износ инструментов в процессе резания металлов. - М.: Машиностроение, 1981.-279 с.
37. Karla P. Monroy Vazquez, Claudio Giardini, Elisabetta Ceretti, Cutting Force Modeling, CIRP Encyclopedia of Production Engineering-2014, pp. 315-329.
38. Zuperl U. A generalized neural network model of ball-end milling force system / U. Zuperl, F. Cus, B. Mursec, T. Ploj // Journal of Materials Processing Technology. – 2006. – Vol. 175, №1-3. – P. 98-108.
39. Aykut S. Modeling of cutting forces as function of cutting parameters for face milling of stellite 6 using an artificial neural network / S. Aykut, M. Golcu, S. Semiz, H.S. Ergur // Journal of Materials Processing Technology. – 2007. – Vol. 190, №1-3. – P. 199-203.
40. Prediction of cutting force for self-propelled rotary tool using artificial neural networks / W. Hao, X. Zhu, X. Li, G. Turyagyenda // Journal of Materials Processing Technology. – 2006. – Vol. 180, №1-3. – P. 23-29.
41. Korkut I. Application of regression and artificial neural network analysis in modelling of tool–chip interface temperature in machining / I. Korkut, A. Acir, M. Boy // Expert Systems with Applications. – 2011.
42. Дуюн Т.А., Рубанов В.Г., Хуртасенко А.В., Гринек А.В., Кариков Е.Б., Лесунов М.Е., Математическое моделирование и оптимизация процессов механической обработки как средство управления технологическими параметрами на основе нечеткой логики, Грант РФФИ и Правительства Белгородской области в рамках проекта №14-41-08044, 2014.
43. Rastee D. Koyee, Siegfried Schmauder, Uwe Heisel & Rocco Eisseler (2015). Numerical modeling and optimization of machining duplex stainless steels, Production & Manufacturing Research, 3:1, 36-83, DOI: 10.1080/21693277.2014.990539.
44. Хайкин С. Нейронные сети: полный курс, 2-издание.: Пер. с англ. – М.: Издательский дом «Вильямс», 2006. - 1104 с.
45. Хоанг В.Ч., Сальников В.С. Выбор оптимального варианта комплекса исходных параметров в математической модели температуры резания // Известия ТулГУ. Технические науки. Выпуск 11: в 2 ч. 2014. Ч.1. С. 402-405.
46. Круглов В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика. - 1-е. - М.: Горячая линия. - Телеком, 2001. - С. 382.
47. Рудой Г.И. Выбор функции активации при прогнозировании нейронными сетями // Машинное обучение и анализ данных. - 2011. - №1. - С. 40-50.
48. Hung-Han Chen, Michael T. Manry And Hema Chandrasekaran. A neural network training algorithm utilizing multiple set of linear equations // Neurocomputing, vol. 40, No.1, January 1992, pp. 202-210.

49. Патент на изобретение № 2566979 РФ. МПК8 G06N 3/02 (15.12.2015). Способ обучения искусственной нейронной сети / В.С. Сальников, В.Ч. Хоанг, А.В. Анцев.
50. Хоанг В.Ч., Сальников В.С. Моделирование температуры резания в условиях неопределенности с применением искусственной нейронной сети // Известия ТулГУ. Технические науки. Выпуск 11: в 2 ч. 2014. Ч.1. С. 386-395.
51. Евсеев Л.Л. Исходные положения и зависимости для расчета характеристик динамики процесса резания металлов // Вестник машиностроения. - 1995. - №12. - с. 29-32.
52. Патент RU 2 535 839 С2 МПК8 В23В 1/00 (20.12.2014) Способ определения оптимальной скорости резания / Е.В. Артамонов, Д.В. Васильев.

Hoang Van Chi

Tula state university, Russia, Tula
E-mail: Hoangchi.phd@gmail.com

Salnikov Vladimir Sergeevs

Tula state university, Russia, Tula
E-mail: tst@tsu.tula.ru

Neural network approach in modeling of temperature-force characteristics of the cutting process

Abstract. A review of the literature on the use of artificial neural network in the machining process control systems and, in particular, to the monitoring systems, the process of cutting the state. The model of temperature-force characteristics of the cutting process, built on an artificial neural network, and takes into account control and disturbing influences. A modified algorithm for its training, ensuring reduced time and learning errors when the same amount of training sample. Described in detail the method of modeling the temperature in the cutting area and cutting force using the artificial neural network trained on the basis of experimental research data of temperature-force characteristics of the cutting process. As a result of comparative studies proved the prospects of using neural network approach to modeling of the cutting process in the face of uncertainty when compared with traditional methods. The proposed model and algorithm for learning should be used in the adaptive control of the cutting process systems.

Keywords: cutting; modeling; training; neural network

REFERENCES

1. Briceno J.F. Selecting an artificial neural network for efficient modeling and accurate simulation of the milling process / J.F. Briceno, H. El-Mounayri, S. Mukhopadhyay // *International Journal of Machine Tools and Manufacture*. – 2002. – Vol. 42, №6. – P. 663-674.
2. Mandal D. Modeling of electrical discharge machining process using back propagation neural network and multi-objective optimization using non-dominating sorting genetic algorithm-II / D. Mandal, S.K. Pal, P. Saha // *Journal of Materials Processing Technology*. – 2007. – Vol. 186, №1-3. – P. 154-162.
3. Yang H. Dynamic neural network modeling for nonlinear, nonstationary machine tool thermally induced error / H. Yang, J. Ni // *International Journal of Machine Tools and Manufacture*. – 2005. – Vol. 45, №4-5. – P. 455-465.
4. Modelling the correlation between cutting and process parameters in high-speed machining of Inconel 718 alloy using an artificial neural network / E.O. Ezugwu, D.A. Fadare, J. Bonney, R.B. Da Silva, W.F. Sales // *International Journal of Machine Tools and Manufacture*. – 2005. – Vol. 45, №12-13. – P. 1375-1385.
5. Kim H.-Y. Chip disposal state monitoring in drilling using neural network based spindle motor power sensing / H.-Y. Kim, J.-H. Ahn // *International Journal of Machine Tools and Manufacture*. – 2002. – Vol. 42, №10. – P. 1113-1119.
6. Kwak J.-S. Neural network approach for diagnosis of grinding operation by acoustic emission and power signals / J.-S. Kwak, M.-K. Ha // *Journal of Materials Processing Technology*. – 2004. – Vol. 147, №1. – P. 65-71.

7. Korosec M. Neural network based manufacturability evaluation of free form machining / M. Korosec, J. Balic, J. Kopac // *International Journal of Machine Tools and Manufacture*. – 2005. – Vol. 45, №1. – P. 13-20.
8. Benardos P.G. Prediction of workpiece elastic deflections under cutting forces in turning / P.G. Benardos, S. Mosialos, G.-C. Vosniakos // *Robotics and Computer-Integrated Manufacturing*. – 2006. – Vol. 22, №5-6. – P. 505-514.
9. Arul S. Online monitoring of acoustic emission for quality control in drilling of polymeric composites / S. Arul, L. Vijayaraghavan, S.K. Malhotra // *Journal of Materials Processing Technology*. – 2007. – Vol. 185, №1-3. – P. 184-190.
10. Sistema kontrolja i metody raspoznavanija sostojanij rezcov dlja podderzhanija ih rabotosposobnosti / A.G. Derevjanchenko, L.V. Bovnegra, D.A. Krinicyn, E.V. Koss, A.A. Fomin // *Naukovi praci DonNTU. Proektuvannja progresivnih konstrukcij rizal'nih instrumentiv ta tehnologichnogo osnashhennja*. – 2009. – S. 87–94.
11. Derevjanchenko O.G. Viktoristannja zasobiv shtuchnogo intelektu pri stvorenni sistemi pidtrimki pracezdatnosti rizhuchih instrumentiv / O.G. Derevjanchenko, R.G. Dolishhins'kij, D.O. Krinicin // *Visnik ZhDTU. Tehnichni nauki*. – 2009. – №3 (50). – S. 32–38.
12. Vnukov Ju.N. Modelirovanie iznosa instrumenta po rezul'tatam vejjvlet-preobrazovanija zvukovogo signala / Ju.N. Vnukov, V.I. Dubrovin, Ju.S. Afonin, T.V. Manilo // *Shtuchnij intelekt*. – 2008. – №1. – S. 73–79.
13. Fines J.M. Machine tool positioning error compensation using artificial neural networks / J.M. Fines, A. Agah // *Engineering Applications of Artificial Intelligence*. – 2008. – Vol. 21, №7. – P. 1013-1026.
14. Mize C.D. Neural network thermal error compensation of a machining center / C.D. Mize, J.C. Ziegert // *Precision Engineering*. – 2000. – Vol. 24, №4. – P. 338-346.
15. Uros Z. Adaptive network based inference system for estimation of flank wear in endmilling / Z. Uros, C. Franc, K. Edi // *Journal of Materials Processing Technology*. – 2009. – Vol. 209, №3. – P. 1504-1511.
16. Cus F. Approach to optimization of cutting conditions by using artificial neural networks / F. Cus, U. Zuperl // *Journal of Materials Processing Technology*. – 2006. – Vol. 173, №3. – P. 281-290.
17. Jain R.K. Optimum selection of machining conditions in abrasive flow machining using neural network / R.K. Jain, V.K. Jain // *Journal of Materials Processing Technology*. – 2000. – Vol. 108, №1. – P. 62-67.
18. El-Mounayri H. Optimization of CNC ball end milling: a neural network-based model / H. El-Mounayri, H. Kishawy, J. Briceno // *Journal of Materials Processing Technology*. – 2005. – Vol. 166, №1. – P. 50-62.
19. Hambli R. Application of a neural network for optimum clearance prediction in sheet metal blanking processes / R. Hambli, F. Guerin // *Finite Elements in Analysis and Design*. – 2003. – Vol. 39, №11. – P. 1039-1052.
20. Kim H.-G. Performance evaluation of chip breaker utilizing neural network / H.-G. Kim, J.-H. Sim, H.-J. Kweon // *Journal of Materials Processing Technology*. – 2009. – Vol. 209, №2. – P. 647-656.

21. Medvedev V.V. Osobennosti diagnostiki kachestva mehanooobrabotki s primeneniem intellektual'nyh sistem / V.V. Medvedev, V.S. Medvedev // Visnik Donbas'koï derzhavnoï mashinobudivnoï akademii. – 2008, №3E (14). – S. 131–135.
22. Tsao C.C. Tool wear and surface roughness prediction using an artificial neural network (ANN) in turning steel under minimum quantity lubrication (MQL) / C.C. Tsao, H. Hochen // Engineering and Technology. – 2010. – №62. – P. 830-839.
23. Ozel T. Predictive modeling of surface roughness and tool wear in hard turning using regression and neural networks / T. Ozel, Y. Karpat // International Journal of Machine Tools and Manufacture. – 2005. – Vol. 45, №4-5. – P. 467-479.
24. Abburi N.R. A knowledge-based system for the prediction of surface roughness in turning process / N.R. Abburi, U.S. Dixit // Robotics and Computer-Integrated Manufacturing. – 2006. – Vol. 22. – №4. – P. 363-372.
25. The experimental investigation of the effects of uncoated, PVD - and CVD-coated cemented carbide inserts and cutting parameters on surface roughness in CNC turning and its prediction using artificial neural networks / M. Nalbant, H. Gokkaya, I. Toktas, G. Sur // Robotics and Computer-Integrated Manufacturing. – 2009. – Vol. 25, №1. – P. 211-223.
26. Oktem H. Prediction of minimum surface roughness in end milling mold parts using neural network and genetic algorithm / H. Oktem, T. Erzurumlu, F. Erzincanli // Materials & Design. – 2006. – Vol. 27, №9. – P. 735-744.
27. Zain A.M. Prediction of surface roughness in the end milling machining using Artificial Neural Network / A.M. Zain, H. Haron, S. Sharif // Expert Systems with Applications. – 2010. – Vol. 37, №2. – P. 1755-1768.
28. El-Sonbaty I.A. Prediction of surface roughness profiles for milled surfaces using an artificial neural network and fractal geometry approach / I.A. El-Sonbaty, U.A. Khashaba, A.I. Selmy, A.I. Ali // Journal of Materials Processing Technology. – 2008. – Vol. 200, №1-3. – P. 271-278.
29. Panda S.S. Simultaneous prediction of surface roughness and drill flank wear in drilling a mild steel work piece using ANN, National Conference on Quality, Reliability and Maintainability aspect in Engineering systems. – 2007.
30. Tsao C.C. Evaluation of thrust force and surface roughness in drilling composite material using Taguchi analysis and neural network / C.C. Tsao, H. Hocheng // Journal of Materials Processing Technology. – 2008. – Vol. 203, №1-3. – P. 342-348.
31. S.T. A. Niaki and M. Davoodi, Designing a multivariate-multistage quality control system using artificial neural networks, International journal of production research: American Institute of Industrial Engineers; Society of Manufacturing Engineers. - London: Taylor & Francis, ISSN 0020-7543, ZDB-ID 1604776. - Vol. 47.2009, 1 (1.1.), p. 251-271.
32. Cory Runyon Real-time quality control of the injection molding process using artificial neural networks / Thesis (M.S.)-Brigham Young University. Dept. of Manufacturing Engineering and Engineering Technology. Includes bibliographical references (leaves [82]-84).
33. D.E. Dimla jr, P.M. Lister and N.J. Leighton, neural network solutions to the tool condition monitoring problem in metal cuttng-a critical review of methods. Int. L Mich. Tools Mlumfla: t. Vol. 37. No. 9. pp. 1219-1241. 1997.

34. Silin, S.S. Metod podobija pri rezanii materialov Tekst. M.: Mashi-nostroenie, 1979. - 152 s.
35. Reznikov A.N. 1981 Teplofizika processov mehanicheskoj obrabotki materialov.
36. Jakobs G.Ju., Jakob Je., Kohan D., Danijeljan A.M. Teplota i iznos instrumentov v processe rezanija metallov. - M.: Mashinostroenie, 1981.-279 s.
37. Karla P. Monroy Vazquez, Claudio Giardini, Elisabetta Ceretti, Cutting Force Modeling, CIRP Encyclopedia of Production Engineering-2014, pp. 315-329.
38. Zuperl U. A generalized neural network model of ball-end milling force system / U. Zuperl, F. Cus, B. Mursec, T. Ploj // Journal of Materials Processing Technology. – 2006. – Vol. 175, №1-3. – P. 98-108.
39. Aykut S. Modeling of cutting forces as function of cutting parameters for face milling of stellite 6 using an artificial neural network / S. Aykut, M. Golcu, S. Semiz, H.S. Ergur // Journal of Materials Processing Technology. – 2007. – Vol. 190, №1-3. – P. 199-203.
40. Prediction of cutting force for self-propelled rotary tool using artificial neural networks / W. Hao, X. Zhu, X. Li, G. Turyagyenda // Journal of Materials Processing Technology. – 2006. – Vol. 180, №1-3. – P. 23-29.
41. Korkut I. Application of regression and artificial neural network analysis in modelling of tool–chip interface temperature in machining / I. Korkut, A. Acir, M. Boy // Expert Systems with Applications. – 2011.
42. Dujun T.A., Rubanov V.G., Hurtasenko A.V., Grinek A.V., Karikov E.B., Lesunov M.E., Matematicheskoe modelirovanie i optimizacija processov mehanicheskoj obrabotki kak sredstvo upravlenija tehnologicheskimi parametrami na osnove nechetkoj logiki, Grant RFFI i Pravitel'stva Belgorodskoj oblasti v ramkah proekta №14-41-08044, 2014.
43. Rastee D. Koyee, Siegfried Schmauder, Uwe Heisel & Rocco Eisseler (2015). Numerical modeling and optimization of machining duplex stainless steels, Production & Manufacturing Research, 3:1, 36-83, DOI: 10.1080/21693277.2014.990539.
44. Hajkin S. Nejrornyje seti: polnyj kurs, 2-izdanie.: Per. s angl. – M.: Izdatel'skij dom «Vil'jams», 2006. - 1104 s.
45. Hoang V.Ch., Sal'nikov V.S. Vybor optimal'nogo varianta kompleksa ishodnyh parametrov v matematicheskoj modeli temperatury rezanija // Izvestija TulGu. Tehnicheskie nauki. Vypusk 11: v 2 ch. 2014. Ch.1. S. 402-405.
46. Kruglov V.V., Borisov V.V. Iskusstvennye nejrornyje seti. Teorija i praktika. - 1-e. - M.: Gorjachaja linija. - Telekom, 2001. - S. 382.
47. Rudoj G.I. Vybor funkcii aktivacii pri prognozirovanii nejrornyimi setjami // Mashinnoe obuchenie i analiz dannyh. - 2011. - №1. - S. 40-50.
48. Hung-Han Chen, Michael T. Manry And Hema Chandrasekaran. A neural network training algorithm utilizing multiple set of linear equations // Neurocomputing, vol. 40, No.1, January 1992, pp. 202-210.
49. Patent na izobretenie № 2566979 RF. MPK8 G06N 3/02 (15.12.2015). Sposob obuchenija iskusstvennoj nejrornoj seti / V.S. Sal'nikov, V.Ch. Hoang, A.V. Ancev.

50. Hoang V.Ch., Sal'nikov V.S. Modelirovanie temperatury rezanija v uslovijah neopredelennosti s primeneniem iskusstvennoj nejronnoj seti // Izvestija TulGu. Tehnicheskie nauki. Vypusk 11: v 2 ch. 2014. Ch.1. S. 386-395.
51. Evseev L.L. Ishodnye polozhenija i zavisimosti dlja rascheta harakteristik dinamiki processa rezanija metallov // Vestnik mashinostroenija. - 1995. - №12. - s. 29-32.
52. Patent RU 2 535 839 C2 MPK8 B23B 1/00 (20.12.2014) Sposob opredelenija optimal'noj skorosti rezanija / E.V. Artamonov, D.V. Vasil'ev.