Сазыкина О.В.,
Норильский индустриальный институт

ИННОВАЦИОННО-ПРОИЗВОДСТВЕННЫЙ ПОТЕНЦИАЛ КАК КРИТЕРИЙ ОЦЕНКИ ФУНКЦИОНИРОВАНИЯ ХОЗЯЙСТВЕННОЙ ДЕЯТЕЛЬНОСТИ ПРОМЫШЛЕННОГО ПРЕДПРИЯТИЯ

Рассматривается система оценки хозяйственной деятельности и потенциала развития предприятия. Предложен интегральный критерий – инновационно-производственный потенциал, рассмотрена схема оценки, мониторинга и прогнозирования производственных процессов. Проанализирована методология использования различных типов нейронных сетей для моделирования.

Формирование эффективной системы оценки, прогнозирования и планирования развития организаций является одной из важных задач, решением которой в настоящее время необходимо заниматься предприятиям как хозяйственным системам. При этом необходимо учитывать не только способность предприятия производить продукцию и удовлетворять потребности рынка, но и экономичность использования ресурсов для этой цели. Учет величины накопленных ресурсов, степени использования потенциальных возможностей организации, как правило, оценивается системой экономических показателей, характеризующих производственно-хозяйственную деятельность предприятия. Для оценки экономических возможностей эффективного развития организации можно использовать комплексный показатель – потенциал хозяйственной системы, использование которого дает возможность судить о реальных возможностях каждой организации и ее скрытых резервах.

В научной литературе приводится определение термина «потенциал» как «средства, запасы, источники, имеющиеся в наличии и могущие быть мобилизованы, приведены в действие, использованы для достижения определенных целей, осуществления плана; решения какой-либо задачи; возможности отдельного лица, общества, государства в определенной области».

Потенциал организаций – главный критерий целесообразности их существования. Через развитие потенциала идет развитие организации и ее подразделений, а также элементов производственно-хозяйственной системы. Потенциал организации имеет две составляющие: готовность ее к стабильной производственной деятельности и готовность к инновациям, поэтому при оценке потенциальных возможностей предприятия целесообразно говорить об его *инновационно-производственном потенциале* (ИПП).

Основой ИПП предприятия является производственный потенциал. В научных исследованиях нет единого мнения по определению производственного потенциала как категории. Но наиболее широкое распространение получил ресурсный подход, согласно которому производственный потенциал – это отношения, которые возникают между работниками предприятия по поводу получения максимально возможного производственного результата, который может быть получен при наиболее эффективном использовании производственных ресурсов, при имеющемся

уровне технологии, передовых формах организации производства. Другими словами, производственный потенциал предприятия – это потенциальный объем производства продукции, потенциальные возможности основных средств, потенциальные возможности использования сырья и материалов, потенциальные возможности профессиональных кадров.

Рыночная экономика вынуждает предприятия более активно использовать такие интенсивные факторы роста производства, как качественное преобразование технической базы производства: увеличение выпуска продукции за счет технического перевооружения, ввода новых технологий, т.е. заниматься инновационной деятельностью.

Инновационный потенциал предприятия– это степень его готовности выполнить задачи, обеспечивающие достижение поставленной инновационной цели, т.е. степень готовности к реализации инновационного проекта или программа инновационных преобразований и внедрения инноваций. Причем, надо отметить, что понятие «инновация» относится ко всем новшествам в производственной, организационной, финансовой и других сферах, к любым усовершенствованиям, обеспечивающим экономию затрат.

Инновационно-производственный потенциал применительно к отдельному предприятию должен характеризовать не столько отдельно инновационные и отдельно производственные возможности, сколько интегральные способности предприятия к максимизации эффективности своей деятельности с помощью рационального использования своих ресурсов и адекватной реакции на влияние факторов внешней среды. Для обеспечения стабильной работы предприятия, его конкурентоспособного положения в рыночной среде необходимо осуществлять постоянный мониторинг инновационно-производственного потенциала предприятия.

Таким образом, с нашей точки зрения, структурно ИПП должен состоять из производственного, отдельно трудового и инновационного потенциалов. Последний, в свою очередь, включает в себя организационно-управленческий потенциал и уровень инновационной активности организации (рис. 1). Под инновационной активностью предприятия следует понимать обобщающую характеристику интенсивности инновационной деятельности, базирующуюся на мобильности инновационного потенциала.

Несмотря на то, что понятийный аппарат оценочных показателей давно выработан, до настоящего времени некоторые аспекты продолжают оставаться дискуссионными. Так, система показателей, характеризующих производственный потенциал (состояние основных и оборотных средств) и трудовой потенциал достаточно хорошо проработана, в отличие от особенностей системы показателей эффективности организационно-управленческих структур и показателей, характеризующих инновационную активность, на уровне развития отдельной производственной системы как хозяйствующего субъекта.

Для оценки организационно-управленческого потенциала предлагается использовать показатели, характеризующие: структуру аппарата управления организации; уровни его компетенции, зарплатоемкости, оснащенности, стабильности и результативности.

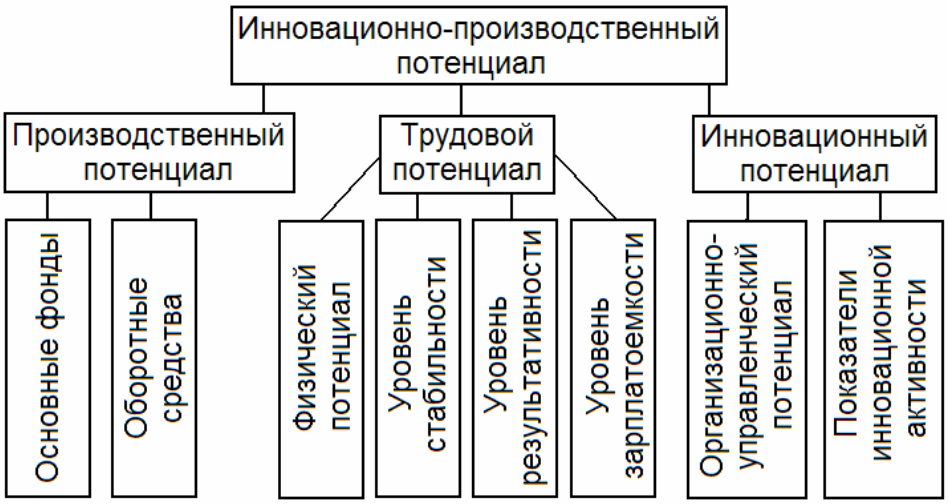

Рис. 1. Структура инновационно-производственного потенциала

Инновационную активность организации характеризуют такие показатели как: удельный вес персонала, занятого инновационной деятельностью; годовой экономический эффект от инноваций к общему объему затрат на их создание; удельный вес стоимости основных фондов, используемых в процессе инновационной деятельности, к среднегодовой стоимости активной части основных фондов; затраты на модернизацию и обновление технологического оборудования к общим затратам на эксплуатацию и ремонты активной части основных фондов; удельный вес персонала, занятого инновационной деятельностью; удельный вес инновационных затрат в выручке от реализации продукции в расчете на одного работающего в организации.

При мониторинге производственной деятельности промышленного предприятия [1] необходимо иметь ввиду, что действенность производственной системы оценивается, как правило, по его промежуточным и конечным результатам. В качестве промежуточных результатов предлагается использовать величины производственного, трудового и инновационного потенциалов. Следовательно, интегральной характеристикой развития организации может служить ИПП. Порядок оценки, мониторинга и прогнозирования на основе инновационно-производственного потенциала представлен на рис. 2.

В ходе анализа ИПП в соответствии с предлагаемой моделью выявляются и анализируются причины несоответствия реального состояния потенциала его желаемой величине. Содержательный анализ предлагается проводить в следующей последовательности: анализ интегрального показателя хозяйственной деятельности предприятия; анализ параметров состояния предприятия (производственный, трудовой и инновационный потенциалы); анализ показателей отдельных характеристик внутренней среды предприятия.

Поскольку для оценки такого критерия, как ИПП, характеризующего возможности развития предприятия, требуется определение множества показателей, т.е. необходимо исследование большого объема информации, а от возможности и скорости обработки этой информации зависит качество управления, то для решения этой задачи необходимо использовать эффективное

средство для переработки больших информационных потоков. В подготовке принятия решений как в зарубежной, так и отечественной практике все большее приложение находят искусственные нейронные сети (НС), которые могут прогнозировать будущие значения переменных по уже имеющимся значениям этих же или других переменных, предварительно осуществив процесс так называемого обучения на основе имеющихся данных.

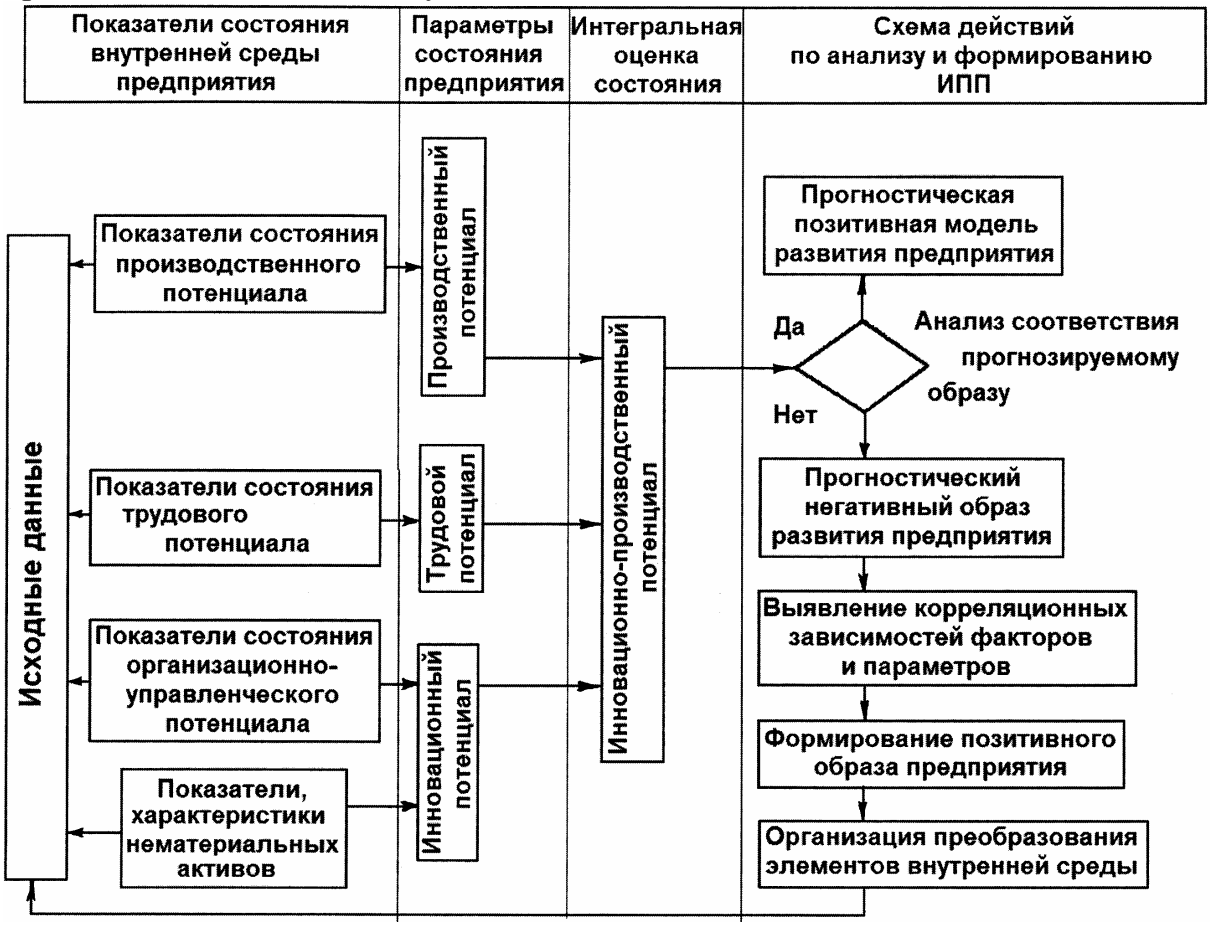

Рис. 2. Структурная схема оценки и совершенствования производственных процессов промышленного предприятия

Автором использована методология применения интеллектуальных средств для поддержки принятия решений по управлению производством. Модель инновационно-производственного потенциала промышленного предприятия реализуется с помощью нейронной сети, составной частью которой являются однотипные элементы-ячейки, – искусственные нейроны. Входной адаптивный умножитель НС вычисляет скалярное произведение вектора входного сигнала $\boldsymbol{X}$ (составляющих ИПП) на вектор-строку весов $\boldsymbol{W}$ (значения составляющих ИПП). Скалярный входной сигнал x_i умножается на скалярный весовой коэффициент w_i. Адаптивность умножителя проявляется в настраивании коэффициентов $w \in W$, происходящем при обучении НС. Умножитель выполняет функцию синапса – однонаправленной входной связи нейрона с его ядром. Каждый синапс характеризуется величиной связи или синапсическим весом – коэффициентом w_i. Передаточная функция нейрона

реализуется нелинейным преобразователем с помощью активационной функции *f(s)*, в которой функция текущего состояния нейрона становится ее аргументом. Автором применялись две нелинейных функции: логистическая однополярная функция и биполярная сигмоидная функция гиперболического тангенса.

Многослойные сети обладают мощными возможностями: НС может быть обучена аппроксимировать с произвольной точностью любую функцию с конечным числом точек разрыва [2]. Многослойная сеть (рис. 3.) в каждом слое имеет свою матрицу весов, вектор смещения и вектор выхода ИПП. Различные слои имеют различное число нейронов. Выходы каждого промежуточного слоя служат входами для следующего слоя.

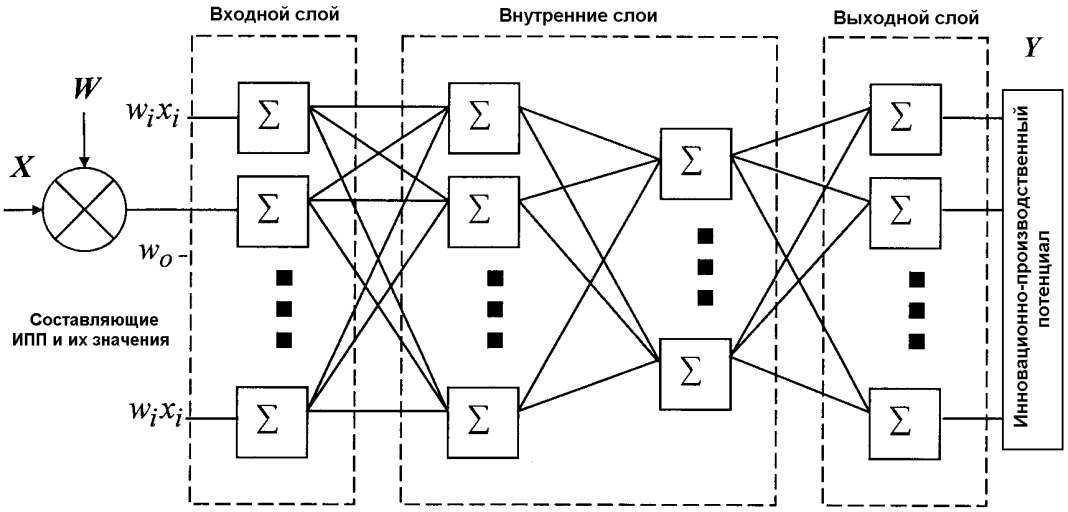

Рис. 3. Структурная схема многослойной НС для расчета ИПП

Способность НС выполнять свои функции зависит как от архитектуры сети, так и от коэффициентов синапсических весов, входящих в множества численных значений составляющих ИПП $\boldsymbol{W}$ и $\boldsymbol{W_O}$. Для выполнения поставленной задачи после определения структуры сети на этапе обучения НС устанавливаются оптимальные значения всех коэффициентов синапсических весов путем их тщательного подбора.

В процессе работы НС формирует вектор выходной информации $\boldsymbol{Y}$ – ИПП в соответствии с вектором входной информации $\boldsymbol{X}$, реализуя функцию

$$\forall f \in F : \boldsymbol{Y} = f(\boldsymbol{X}), \qquad (1)$$

где F – универсум функций f.

При заданной архитектуре НС функция f определяется значениями коэффициентов синапсических весов $\boldsymbol{W}$ и $\boldsymbol{W_O}$. Помимо этих параметров, вводится специальная функция ошибки $E(w)$ или функционал качества. Для функции ошибки используется сумма квадратов разности ошибок согласно методу наименьших квадратов. НС обучают, подавая компоненты входного вектора по одному на вход и подстраивая весовые коэффициенты до тех пор, пока для всех компонентов выходного вектора не будет достигнут результат требуемой точности. Каждая эпоха (итерация) алгоритма обучения состоит в вычислении выходного компонента. Если при подаче входного компонента

выходной компонент соответствует требуемому результату, то ничего не меняется и осуществляется переход к следующей эпохе. Если выходной компонент не соответствует требуемому результату, то коэффициенты синапсического веса модифицируются для уменьшения ошибки. Численные эксперименты показали, что функция ошибки при увеличении количества эпох уменьшается только до определенного момента, после чего начинает расти. Слишком длительное обучение может привести к *переобучению* сети, которое выражается в адаптации весовых коэффициентов к несущественным отклонениям обучающих данных, поскольку исходные данные, как правило, задаются с погрешностями. Для того чтобы выявить факт переобучения используется часть обучающих данных V, зарезервированных для независимого контроля и не использованных при обучении НС

$$\forall R: \; L \in R, \quad V \subset L, \quad G \in R, \tag{2}$$

где R – универсум входных данных, на котором выполняется правило соответствия $\boldsymbol{X} \rightarrow \boldsymbol{Y}$; L – обучающее множество; V – контрольное множество; G – тестовое множество.

Для обобщения информации НС должна тренироваться на избыточном множестве данных, поскольку тогда весовые коэффициенты будут адаптироваться к статистически усредненным показателям.

Имеющиеся особенности НС приводят к тому, что структура связей НС становится для пользователя логически непонятной. Невозможно построить понятную логическую конструкцию, воспроизводящую действия НС, что является логической непрозрачностью нейронных сетей, обученных по неявным правилам. НС вычисляют как линейные функции, так и нелинейные функции одного переменного, а также всевозможные суперпозиции – функционалы (функции от функций), получаемые при каскадном соединении нейронов и слоев. Это создает *проблему адекватности* (способности отражать характеристики с некоторой допустимой относительной погрешностью) нейросетевого моделирования задач критериальной оценки, и связанные с ней вопросы точного вычисления одних функций и аппроксимации других. Степень адекватности нейросетевого моделирования первоначально рассмотрена на решении часто используемой в области анализа производственных процессов – задачи линейной регрессии. Поскольку для получения результатов по уравнению регрессии НС обучается на минимизации ошибки E, то принимая, например, значение ошибки $E = 0{,}05$ при доверительной вероятности выходных данных $0{,}95$, в соответствии с критериями Фишера (для малых выборок), Пирсона или Колмогорова (для больших выборок) получается технически адекватная нейросетевая модель. НС, принимая на входе вектор данных $\boldsymbol{X}$, вычисляет его скалярное произведение на вектора синапсических весов $\boldsymbol{W}$, $\boldsymbol{W_O}$, и формирует функцию одного переменного $f(s)$. Результат $\boldsymbol{Y} = f(s)$ передается на входы других нейронов или на выход сети. Таким образом, НС вычисляет суперпозиции функции одного переменного и их линейные сочетания.

Кроме точного представления ИПП – функции многих переменных (основные фонды, оборотные средства, нематериальные активы и т.д. по рис. 1) с помощью функций одного переменного существует не менее важная проблема аппроксимации, поскольку на практике вычисление большинства

функций производится приближенно. Аппроксимация функций многочленами и рациональными функциями реализуется согласно теореме Вейерштрасса: непрерывную функцию нескольких переменных $f(x_1, x_2, ..., x_n)$ – ИПП на замкнутом ограниченном множестве Q – множестве показателей производственных процессов можно равномерно приблизить последовательностью полиномов. Для любого значения ошибки $E > 0$ существует такой многочлен $P(x_1, x_2, ..., x_n)$, что

$$\min_{Q} | f(x_1, x_2, ..., x_n) - P(x_1, x_2, ..., x_n) | < E . \qquad (3)$$

Следовательно, с помощью линейных операций и каскадного соединения нейронов НС можно из произвольных нелинейных элементов получить требуемый результат с любой заранее заданной точностью, что свидетельствует об адекватности моделирования ИПП нейронными сетями. Для создания адекватных нейросетевых моделей в процессе обучения многослойных НС при использовании градиентных способов необходимо знать вектора градиента Δw для всех слоев сети. Задача этого вопроса состоит в определении ошибки для нейронов скрытых слоев и вычислении $grad_w$ по методу получил название BProp – методу обратного распространения ошибки [3]

$$E(w) = \frac{1}{2}\sum_k (f(\sum_k w_{ki} z - d_k))^2 = \frac{1}{2}\sum_k (f(\sum_k w_{ki} f(\sum_i w_i x_i)) - d_k)^2 . \quad (4)$$

Составляющие градиента определяются результатом дифференцирования функции (4). Следовательно, окончательное выражение для наибольшей скорости изменения Δw в требуемом направлении, имеющего вид отрицательного градиента $\Delta w = grad_w \Delta = -\Delta \cdot x$, будет записано в виде

$$\Delta w_{ij}^{(n)} = -h \cdot d_j^{(n)} \cdot y_i^{(n-1)} , \qquad (5)$$

где $\Delta w_{ij}^{(n)}$ – градиент, реализуемый *j*-м нейроном, для *i*-го весового коэффициента *n*-го слоя НС; $d_j^{(n)}$ – величины ошибки *n*-го слоя по величинам ошибки следующего за ним *(n+1)*-го слоя; $y_j^{(n-1)}$ – данные *j*-го нейрона предыдущего *(n-1)*- го слоя.

Существенным недостатком рассмотренного выше метода BProp, используемого для обучения многослойных НС, является длительный процесс их обучения. В настоящее время известен ряд эвристических методов ускорения процесса обучения. Один из быстрых методов градиентного спуска RProp (Resilient Propagation – эластичное распространение [4]) применяет для подбора весовых коэффициентов знаки частных производных, а не их значения. Настройка весовых коэффициентов выполняется по модифицированному градиенту:

$$\Delta w_{ij} = -h \cdot \Delta_{ij} \cdot \mathrm{sgn}(\P E / \P w_{ij}) , \qquad (6)$$

где Δ_{ij} – величина коррекции; $\mathrm{sgn}(\P E / \P w_{ij}) = \pm 1$ – функция, принимающая значение, равное знаку градиента $\P E / \P w_{ij}$.

Метод использует обучение по эпохам *t*, когда коррекция весовых коэффициентов происходит после ввода всех примеров из обучающей *L*

выборки. В тех случаях, когда угол наклона целевой функции не велик, рассмотренный метод игнорирования ИПП по значению градиента позволяет значительно ускорить процесс обучения.

В работе [5] обосновано использование обучающих методов сопряженных градиентов, основанного на решении системы линейных алгебраических уравнений

$$Aw = b, \tag{7}$$

где w – неизвестный вектор (ИПП); b – известный вектор (составляющие ИПП); A – известная, квадратная, симметричная, положительно-определенная матрица (параметры составляющих ИПП), если для любого ненулевого вектора w справедливо неравенство $w^T Aw > 0$. Решение системы (7) эквивалентно нахождению минимума соответствующей квадратичной формы (скалярной квадратичной функции вектора w) следующего вида:

$$f(w) = (1/2)w^T Aw - b^T w + c, \tag{8}$$

где c – смещение функции $f(w)$.

Наличие связи между матрицей линейного преобразования A и скалярной функцией $f(w) \equiv E(w)$ дает возможность для положительно-определенных матриц вместо решения системы уравнений разложения целевой функции

$$E(w+p) = E(w) + grad(w)^T p + \frac{1}{2} p^T H(w) \cdot p + \ldots, \tag{9}$$

(где ^{T} – знак скалярного умножения векторов) найти минимум ее погрешности за конечное число эпох.

Многослойные НС выполняют аппроксимацию целевой функции нескольких переменных путем преобразования множества входных переменных $\boldsymbol{X}$ во множество выходных переменных $\boldsymbol{Y}$. Вследствие специфики характера сигмоидальной функции активации осуществляется аппроксимация глобального типа. В результате нейрон подобной сети, который был активирован после превышения суммарными данными определенного порогового значения, остается в этом состоянии при любом значении данных, превышающем этот порог. Поэтому всегда преобразование значения функции в произвольной точке гиперпространства выполняется объединенными усилиями многих нейронов путем глобальной аппроксимации.

Автором рассмотрен и другой способ отображения входного множества $\boldsymbol{X}$ в выходное $\boldsymbol{Y}$, который заключается в преобразовании путем адаптации нескольких одиночных аппроксимирующих функций к ожидаемым выходным значениям. Причем адаптация данных проводится только в ограниченной области гиперпространства. При таком подходе отображение всего множества данных представляет собой сумму локальных преобразований. Скрытые нейроны формируют множество базисных функций локального типа при ненулевых значениях в ограниченной области гиперпространства данных, выполняя локальную аппроксимацию. В НС с радиальной базисной функцией (Radial Basis Function – RBF) скрытые нейроны реализуют функции, радиально изменяющиеся вокруг выбранного центра c на оси абсцисс, принимающие ненулевые значения в окрестности этого центра [6, 7]. В таких НС роль

скрытого нейрона заключается в отображении радиального пространства вокруг заданной точки. Суперпозиция данных, поступающих от всех скрытых нейронов, выполняется выходным нейроном и позволяет получить отображение всего гиперпространства, являясь линейной комбинацией некоторого набора базисных функций (составляющих ИПП)

$$\boldsymbol{Y} = f(x) = \sum_{j=1}^{m} w_j \cdot h_j(x), \qquad (10)$$

где m – число нейронов скрытого слоя; $h(x)$ – функция Гаусса.

Обучение RBF сети состоит в нахождении весовых коэффициентов методом псевдообратных матриц, который минимизирует средний квадрат ошибки. RBF сети лучше, чем сигмоидальные решают классификационные задачи. Применение RBF сетей для прогнозирования сложных временных процессов, дает результаты не хуже, чем получаемые с использованием сигмоидальных НС, что позволяет расширить возможности моделирования критериев оценки функционирования практически для всех рассматриваемых производственных процессов промышленных предприятий.

В соответствии с особенностями нейросетевого метода обработки большого объема информации, мониторинг состояния ИПП на предприятии рекомендуется начинать с определения ИПП за предшествующие периоды с последующим сравнением с отчетной величиной. Такое сопоставление дает возможность выявить темп развития предприятия, динамику параметров и показателей хозяйственной системы, позволит выяснить причины несоответствия текущих значений прогнозируемым, что позволит выработать мероприятия по устранению этого несоответствия.

Бенчмаркинг ИПП исследуемого предприятия с аналогичными предприятиями в данном регионе позволит определить место, занимаемое им в ряду других предприятий одной отрасли, перенять опыт и выявить возможные резервы развития.

Интегральная оценка производственной деятельности Норильского предприятия «Механический завод» и соотнесение величины ИПП с конечными результатами функционирования дали комплексное представление о степени использования производственных ресурсов и резервах повышения эффективности производства. При наличии указанных данных появляется возможность более объективного определения направлений оптимизации структуры ИПП и путей его дальнейшего наращивания.

Список литературы

1. Сазыкина О.В. Организация мониторинга инновационно-производственного потенциала промышленного предприятия. Сб. научн. трудов «Организационно-технологические проблемы эффективности производства в условиях Крайнего Севера». – Норильский индустр. инст-т. – Норильск, 2005. – С. 165–169.

2. Медведев В.С., Потемкин В.Г. Нейронные сети. MATLAB 6. – М.: ДИАЛОГ-МИФИ, 2002. – 496 с.

3. Heht-Nielsen R. Theory of the backpropagation neural network. – Neural Networks for Human and Mashine Perception. Vol. 2. – Boston, MA: Academic Press, 1992. – Pp. 65–93.

4. Riedmiller M., Braun H. RPROP – a fast adaptive learning algorithm. Technical Report. – Karlsruhe: University of Karlsruhe, 1992. – Pp. 547–554.

5. Осовский С. Нейронные сети для обработки информации. – М.: Финансы и статистика, 2002. – 344 с.

6. Leonard J.A., Kramer M.A. Radial basis function networks for classifying process faults. – IEEE Control System Magazine. – 1991, April. – Pp. 31–38.

7. Tarassenko L., Roberts S. Supervised and unsupervised learning in radial basis function classifiers. – IEEE Proc. Vis. Image Signal Process. – 1994, vol. 141. – Pp. 210–216.