

УДК 004.8.032.26; 57.089

А.Л. Ляхов, С.П. Алешин

Полтавский национальный технический университет имени Юрия Кондратюка, Украина
LAL@pntu.edu.ua; aleshsp@ukr.net

Нейросетевая модель формулы сбалансированного питания

Работа посвящена проблеме автоматизации принятия решений в построении формулы сбалансированного питания с применением технологий искусственного интеллекта. Предложена методика построения нейросетевой модели базовых процессов поиска оптимального состава ингредиентов. Построены модели кластерного анализа входных данных, классификатора состояний и аппроксиматора многомерной функции. Предлагаемая методика позволяет автоматизировать процесс поиска оптимального состава биологически активных добавок и снизить степень субъективизма в принятии решений.

Введение

Постановка проблемы. Современная нутрициология (наука о питании) подчеркивает растущую угрозу здоровью человека из-за несбалансированности питания. Причин тому несколько, главными из которых являются: дефицит в продуктах питания витаминов и микроэлементов; избыток простых углеводов и жиров; недостаток пищевых волокон; нарушение ритма и режима питания; употребление опасных и вредных продуктов питания; наличие загрязнителей и токсичных веществ; ошибки в кулинарной обработке и заготовке продуктов питания и др. Одним из направлений решения проблемы питания считается использование в рационе биологически активных добавок [1]. Например, в Японии БАДы присутствуют в рационе у 80% населения, в США – 60%, в странах Европы – от 30% до 40%, в странах СНГ – 5%. Биологически активные добавки (БАД) к пище – это композиция натуральных или идентичных натуральным биологически активным веществам, предназначенным для непосредственного приема с пищей или введения в состав пищевых продуктов с целью обогащения пищевого рациона. Недостаток их в продуктах питания способен приводить к дезорганизации обменных процессов в организме, заболеваниям или даже смерти. Однако избыток этих веществ также вреден, так как эти компоненты пищи (белки, аминокислоты, липиды, витамины, микроэлементы и др.) могут изменять или угнетать метаболические процессы, проявлять токсичность. А сбалансированное питание может не только стабилизировать все метаболические процессы в организме, но и может стать достаточно мощным лечебным фактором [2]. Формализовать процессы и найти аналитические зависимости взаимодействия всей совокупности факторов, их взаимосвязей и целевой функции сегодня практически невозможно. Это обстоятельство сдерживает создание автоматических систем принятия решений при назначении формулы ингредиентов БАД. В настоящее время существуют и успешно применяются автоматизированные системы дифференциальной диагностики, многоуровневого распознавания, многофакторного тестирования и др. Однако полного замкнутого цикла автоматического принятия решения о назначении курса БАД в научных публикациях не встречается. Это свидетельствует о том, что проблема перехода от автоматизированных систем диагностики и прогнозирования к автоматическим системам принятия решений существует.

Анализ последних исследований и публикаций. Публикации исследований в этой области отражают определённые успехи в применении интеллектуальных технологий [3]. На базе представительной выборки прецедентов, примеров из практики, технические системы анализа позволяют выявить закономерности в данных, корреляционные связи, информативность отдельных факторов и их сочетаний и построить модель принятия решений. В качестве исходных данных для принятия решений используются результаты физиологических измерений, биохимических анализов, ретроспективные результаты наблюдений субъекта и базы знаний предыстории. Сегодня существует и используется на практике значительный массив программ тестирования, что позволяет распознавать отклонения от нормы и прогнозировать их эволюцию. Однако роль эксперта при принятии окончательного решения остается высокой, что снижает объективность этого решения, а отсутствие доступных и дешёвых автоматических систем заставляет пользователей БАД зачастую полагаться на интуицию. Это снижает эффективность их приема, а в ряде случаев, приносит вред, что позволяет **выделить не решенную ранее часть общей проблемы**, которой и посвящена данная статья, – обоснованию возможности автоматизации процесса принятия решений при назначении формулы сбалансированного питания на основе нейросетевых моделей. Массив данных физиологии, биохимического анализа и предыстории позволяет описать состояние субъекта как образ на языке его информативных признаков и получить набор образов в пересекающемся пространстве признаков. Нейросетевые модели в принципе способны в многомерном пространстве управляющих факторов, признаков состояния субъекта и совокупности прецедентов предыстории, найти вид разделяющей поверхности в виде модифицированного пространства синаптических коэффициентов. Это обстоятельство может стать основой автоматизации принятия решений при комплексном подходе к диагностике, прогнозированию и оптимальному управлению состоянием субъекта, как к задаче распознавания образов в многомерном пространстве признаков в среде стандартных нейроконструкторов. Этап предсказания эволюции состояния субъекта с различным горизонтом прогноза нейронная сеть способна интерпретировать как решение задачи нелинейной регрессии (многомерной зависимости). При этом находится вид зависимости состояния субъекта от входных факторов как отображение пространства входных признаков на пространство выходных состояний и реализуется путем итерационных процедур обучения сети на множестве прецедентов. Так как в составе входных воздействий присутствует и вектор управляющих факторов, то заключительный этап – поиск оптимального управления состоянием субъекта – сводится к выбору целевой функции и обоснованию надежности и точности решений обоснованием доверительных вероятностей и доверительных интервалов.

Постановка задачи, цели и методы исследования. Имеется объект, состоящий из трех подсистем: технические средства диагностики и прогнозирования, группа экспертов и субъект исследований – пациент. Необходимо разработать программную модель набора БАД с целью обеспечения оптимальной динамики эволюции текущего состояния субъекта в целевое и при этом исключить из процесса принятия решений экспертные данные. Для выбора правильной стратегии влияния факторов на конечный результат необходимо построить аппроксимирующую зависимость «факторы – состояние», когда и первые и вторые являются векторными величинами:

$$|y^k| = F |x^m|. \quad (1)$$

Необходимо найти отображение

$$F X \rightarrow Y, X \subset \mathfrak{R}^m, Y \subset \mathfrak{R}^k, \quad (2)$$

где k и m , соответственно, размерность состояний (алфавит классов) и размерность факторов (объем словаря признаков), чтобы по известным значениям вектора входных

факторов $\vec{X} = (x_1, \dots, x_m) \in X$, оценить значения выходного вектора $\vec{Y} = (y_1, \dots, y_k) \in Y$.

Оператор F включает в себя все процедуры преобразований пространства $\vec{X} = (x_1, \dots, x_m) \in X$ в пространство $\vec{Y} = (y_1, \dots, y_k) \in Y$.

Для нахождения адекватного отображения (2) требуется решение трех промежуточных задач:

- оценка начального (текущего) состояния ССТС;
- прогнозирование поведения системы на некотором временном отрезке в будущем;

- подбор соответствующих управляющих факторов, обеспечивающих баланс (1).

В терминах теории управления сложными системами эти задачи представляются, соответственно, как классификация текущего состояния; предсказание поведения объекта по входным данным и состояниям предыстории; оптимальное управление как поиск управляющих факторов соответствующих целевому состоянию объекта [6], [7]. Для моделирования этих процессов логично применить технологию Statsoft в формате модуля Statistika Neural Network и обеспечить условия адекватности модели реальным процессам в рамках требований задачи.

Воспользуемся подходом, предложенным в работе [7]. Определим пространство признаков, описывающих образ исследуемого субъекта. Это набор физиологических данных и результаты биохимического анализа. Физиологию опишем вектором, элементами которого являются числовые значения (рост, вес, давление, температура и т.д.) и категориальные (пол, перенесенные болезни, травмы, образ жизни, вредные привычки и т.д.). Размерность вектора на этом этапе не ограничиваем. Стандартный биохимический анализ крови включает определение различных параметров, отражающих состояние белкового, углеводного, липидного и минерального обмена, а также активность некоторых ключевых ферментов сыворотки крови. Результаты биохимического анализа представим вектором, элементы которого – числовой набор показателей крови (белки, ферменты липиды, углеводы, пигменты, неорганические вещества, витамины и т.д.). Оценка результатов биохимического исследования крови имеет большую диагностическую и прогностическую ценность для решения поставленной задачи, так как показывает, каких микроэлементов и витаминов не хватает в организме. Эта информация является исходным шагом для формирования набора биологически активных добавок (БАД).

Существуют определенные нормы биохимического анализа крови – количество показателей, которое должно присутствовать в крови человека определенного возраста и пола. Это статистически установленные показатели здоровых людей [4], [5]. Отклонение от этих показателей – симптом разнообразных нарушений в деятельности организма, сбой в работе определенных органов или систем. Эти нормы являются основой формирования вектора, описывающего образ целевой функции на языке информативных признаков.

Среднестатистические нормы витаминов и минералов. Витамин А – 1 мг; витамин В1 – 1,7 мг; витамин В2 – 2,0 мг; витамин В3 – 20 мг; витамин В5 – 5,0 мг; витамин В6 – 2,0 мг; витамин В9 – 400 мкг; витамин В12 – 3,0 мкг; витамин С – 70 мг; витамин D – 5,0 мкг; витамин Е – 15 мг; витамин Н – 50 мкг; витамин К – 30 мкг.

Основные минеральные вещества и их дневная потребность. Макроэлементы: кальций – около 800 мг; фосфор – около 250 мг; магний – 400 мг; натрий – около 1 г; калий около 2,5 – 5 г; хлор – около 2 г; сера – около 1 г. Микроэлементы: железо – около 14 мг; цинк – от 8 до 20 мг; йод – 150 мкг; фтор – около 3 мг.

Построение нейросетевой модели формулы сбалансированного питания

В контексте обобщенной математической модели сущность обеспечения сбалансированного питания (оптимального управления объектом) состоит в непрерывной или дискретной оценке текущего состояния объекта, измерения наблюдаемых переменных, сравнении текущего и целевого состояний и выбор значений множества управляющих факторов, адекватных множеству признаков целевого состояния субъекта. Для сложных объектов вид функции связи факторов и состояний целесообразно искать в неявном виде, используя обучающие правила на множестве примеров предыстории других субъектов, а в качестве инструмента реализации использовать модуль Statistika Neural Network пакета технического анализа данных Statistika. Для распознавания состояния субъекта необходимо составить словарь информативных признаков и описать алфавит классов состояний объекта на языке этого словаря. Основными показателями, характеризующими состояние пациента, являются измерения физиологических параметров и результаты биохимического анализа. Эталонное состояние субъекта характеризуется набором приведенных среднестатистических норм в формате пространства физиологических и биохимических признаков. Оптимальное управление выражается в определении числового значения каждого элемента вектора признаков, описывающего формулу сбалансированного питания субъекта (пациента). Таким образом, в качестве элементов вектора входных факторов $\vec{X} = (x_1, \dots, x_m) \in$

X выберем данные физиологии и биохимии. Это набор переменных входной выборки. При необходимости можно дополнить вектор входных параметров и другими показателями (род занятий, образ жизни и т.д.), что, естественно, увеличит размерность входного вектора, но не изменит общей методики классификации состояния. Следующий шаг – формирование алфавита классов $\vec{Y} = (y_1, \dots, y_k) \in Y$. Это группы одноименных показателей (классы), характеризующие качество исследуемого объекта. В данном случае, некоторый набор показателей соответствует, например, оптимальной формуле сбалансированного питания (\vec{Y}_{E1}), второй – приемлемой ФСП (\vec{Y}_{E2}), третий (\vec{Y}_{E3}) – соответствует несбалансированному питанию, четвертый – недопустимому состоянию (\vec{Y}_{E4}). Классы различаются степенью отличий признаков текущего состояния от соответствующих признаков целевого (эталонного) состояния. Можно продолжать наращивать алфавит классов, если в этом есть необходимость по условию конкретной задачи. Для решения это не принципиально.

Так как каждому классу соответствует свой набор показателей, то процедура классификации объекта сводится к анализу пространства признаков текущего состояния и сравнения результатов анализа с описаниями выбранных классов. В нейросетевом формате задача распознавания классов текущего состояния исследуемого субъекта решается, например, с использованием дельта-правила Видроу-Хоффа [6] в такой последовательности:

– выбираем, например, квадратичный вид функции ошибки

$$E(w) = \sum_{k=1}^P (d^k - y^k)^2, \quad (3)$$

где P – размерность вектора входных параметров; y^k – реальный выход сети для k -го признака; d^k – эталонный (целевой) выход сети для k -го признака; w – массив синаптических коэффициентов.

При выборе аналитического вида y^k и d^k воспользуемся подходом, предложенном в [8], где обоснован выбор ошибки обучения с учетом допустимых рисков в предметной области через статистические критерии согласия и описаны процедуры формирования данных, описывающих динамику индикаторов текущего и целевого состояний:

$$y_m(X) = \frac{1}{mL} \sum_{i=1}^m \sum_{l=1}^L I(X_{il} \geq x_{il}), \quad (4)$$

$$d_m(X) = \frac{1}{mK} \sum_{i=1}^m \sum_{k=1}^K [I(X_{ik} \geq d_k^{\min}) - I(X_{ik} \leq d_k^{\max})], \quad (5)$$

где $I(X_{il} \geq x_{il}) = \begin{cases} 1, & \text{если } X_{il} \geq x_{il} \\ 0, & \text{если } X_{il} < x_{il} \end{cases}$; $i = \overline{1, m}$; $l = \overline{1, L}$ – номер управляющего фактора;

L – количество управляющих факторов;

$X = \{X_{il}\}$ – наблюдаемые значения l -го управляющего фактора для i -й выборки,

d_k^{\min} и d_k^{\max} – границы интервалов допустимых значений индикаторов вектора целевого состояния (выбираются из условия допустимых рисков в предметной области).

В нейросетевом формате классификация состояний возможна с помощью обученной сети, когда закончена модификация синаптического пространства на основе итерационной процедуры

$$w_{ij}^{(n)}(t) = w_{ij}(t-1) + \Delta w_{ij}^{(n)}(t), \quad (6)$$

где $\Delta w_{ij} = -\eta \times \frac{\partial E}{\partial w_{ij}}$ – величина модификации отдельного веса; η – параметр, определяющий скорость обучения ($0 < \eta < 1$).

Процесс классификации состояния исследуемого субъекта заключается в подаче на вход обученной сети вектора признаков и фиксации номера класса. Установленный номер класса характеризует текущее состояние субъекта и позволяет установить количественно несовпадение признаков пространств текущего и целевого состояний. Однако предварительно необходимо сформировать обучающее множество на массиве имеющихся прецедентов. В формате технологии Statsoft – это задача кластерного анализа входных данных, решение которой позволяет каждому образу на входе сети поставить в соответствие номер класса. В нашем случае их 4.

Кластерный анализ входных образов

Сформулируем задачу кластерного анализа как задачу описания класса на языке его информативных признаков. Исходные данные располагают числом примеров (наблюдений) 2000 в 24-мерном пространстве признаков (Var 1 – Var 24). Выходная переменная игнорируется, так как априори она зависит от всех остальных и не вносит дополнительной информации. Задача кластеризации в этом случае заключается в разделении входных образов на группы, таким образом, чтобы внутри группы входные вектора были максимально схожи между собой, а сами группы – напротив, максимально между собой различались.

Для решения этой задачи в первую очередь обоснуем метрику сравнения образов, то есть в пространстве входных признаков (Var 1 – Var 24) выберем меру

сходства между ними. Воспользуемся традиционной евклидовой метрикой, которая выражается как корень из суммы квадратов по координатных разностей. В нашем случае каждая координата – это один из 24-х признаков входного вектора. Следует помнить, что абсолютные величины входных признаков измеряются в разных шкалах и имеют разные диапазоны изменений. Это значит, что вклад в евклидову метрику будет зависеть от типа измерительной шкалы признака, что может привести к потере информации о воздействии некоторых факторов. Обеспечить инвариантность меры сходства от типа шкалы поможет процедура стандартизации входных переменных, результатом которой является приведение всех переменных к единой шкале. Важно отметить, что стандартизация данных не изменяет структуру взаимодействия переменных между собой и не влияет на топологию признаков внутри кластеров. Реализация этой функции в среде StatSoft осуществима в контекстном меню раздела Fill / Standardize Block опцией Standardize Columns. Количество кластеров, учитывая особенности предметной области исследуемого объекта, несложно установить экспертным путем. В нашем случае их 4. В основе разделения на кластеры лежит итеративная процедура метода К-средних, которая начинается с задания начальных условий, т.е. числа кластеров и их центров.

Реализация процесса начинается из главного меню Statistics опцией Cluster Analysis. В диалоговом окне Clusterin method выбираем K-means clustering и инициируем сеть (OK). Вызываем стартовую панель этого модуля командой Statistics из основного меню и во вкладке Quick данного диалогового окна в разделе Problem type выберем задачу Classification. Командой Variables вызываем диалоговое окно Select input, output и записываем все переменные по списку (Var 1 – Var 28). В разделе Select analysis выбираем опцию Intelligent Problem Solver, что необходимо для установки параметров сети по умолчанию и фиксации сложности и топологии сети. В диалоговом окне IPS Training In Progress выбираем сеть. Анализ осуществляем по десяти строкам информационного поля диалогового окна. В разделе Profile фиксируем топологию сети (SNN – Kohonen 24:24 – 48:1). На вкладке Advanced в разделе Clusters выберем Cases, а в поле Number of Clusters введем цифру 4 – число классов (кластеров). Сохраним результаты анализа при помощи вкладки Advanced выбором опции Save clustering and distances для сохранения результатов кластеризации и расстояния. В таблице результатов скопируем переменную Cluster и добавим её в исходный файл данных. В строках данной переменной содержатся номера классов, к которым были отнесены в итоге многомерные образы. Кластеризация проведена, классы описаны на языке выбранных признаков и готовы к использованию на втором этапе как обучающие выборки соответствующего класса.

Построение и обучение классификатора

Построим нейросетевую модель, которая по произвольному входному вектору заданной размерности (совокупности 24-х чисел), определяла бы класс (1 – 4), к которому принадлежит субъект. Другими словами, необходимо реализовать процедуру отнесения каждого предъявленного сети множества из словаря признаков (Var 1 – Var 24) определенному кластеру из алфавита классов. Решим эту задачу в нейросреде StatSoft с помощью модуля Neural Networks. Вызываем стартовую панель этого модуля командой Statistics из основного меню и во вкладке Quick данного диалогового окна в разделе Problem type выберем задачу Classification. Командой Variables вызываем диалоговое окно Select input, output и записываем все переменные по списку (Var 1 – Var 28). Конструктор сети позволяет проектировать сеть с количест-

вом входов больше 28. Воспользуемся этой возможностью и зарезервируем дополнительно сегмент переменных до значения (Var 53) на случай увеличения размерности входного множества. Это позволит вводить в формулу сбалансированного питания не только основные нутриенты, но и многие ингредиенты второго плана (селен, хром и др.). В разделе *Selekt analysis* выбираем опцию *Intelligent Problem Solver*, а в окне настройки этой процедуры на вкладке *Quick* установим в разделе *Networks tested*, укажем количество тестируемых сетей, например, 10. Все остальные параметры остаются неизменными. В диалоговом окне *IPS Training In Progress* по информации о времени исполнения алгоритма, значениям ошибок на обучающем, контрольном и тестовом множествах, путем сравнения их между собой, выбираем сеть. Анализ осуществляем по строкам информационного поля диалогового окна. В разделе *Profile* фиксируем топологию сети (SNN – MLP 53:53 – 27 – 4:1). Это важно знать при экспертном выборе компромисса между ошибками, производительностью и временем обучения. Под производительностью в задачах классификации понимается доля правильно классифицируемых наблюдений по отношению к общему числу наблюдений. Для практического применения часто используются значения производительности в диапазоне (0,9 – 0,97). Далее вызываем вкладку *Descriptive Statistics* с таблицей статистик классификации. Столбцы этой таблицы представляют собой наблюдаемые классы, а строки – предсказанные классы. В идеале в этой таблице диагональные элементы должны быть отличны от нуля, а все остальные – нулевые. Это значит, что процент неправильно классифицированных наблюдений равен нулю, а производительность сети равна 1.

Чтобы определить, к какому классу относится многомерное наблюдение, во вкладке *Advanced*, применим опцию *User defined case* для инициализации рабочего режима классификации входных образов. Для этого в окне *Quick* на вкладке *User defined case prediction* задаем входные значения, запустив режим сети *User defined input*, и инициуем *Predictions*. В результате сеть выдает номер класса, которому принадлежит совокупность признаков (входной вектор), описывающих исследуемое состояние субъекта. Эти данные являются исходной информацией для прогнозирования динамики текущего состояния субъекта в направлении целевого. Если результат распознавания соответствует любому классу, кроме первого, начинается следующий этап прогноза динамики состояния от воздействия входного вектора данных.

Прогноз динамики состояний от вариаций элементами входного вектора

На конечном этапе необходимо так варьировать элементами на входе, чтобы обеспечить динамику состояния субъекта в направлении к первому классу. На языке нутрициологии это – реализация процесса сбалансированного питания. Продуктивность вариаций зависит от того, на сколько точно установлен аналитический вид зависимости входных переменных (числовые значения концентрации витаминов и минералов) и выходной переменной (номер класса состояния субъекта). Очевидно, что это задача нелинейной регрессии, которая на вербальном уровне формулируется как построение зависимости переменной *A* от переменных *B*, *C*, *D*... и т.д. с заданной точностью, в рамках временных, информационных и материальных ресурсов. Этот этап также проведем в рамках технологии *StatSoft* и нейросетевой среде *Statistika*.

На основе указанных условий решаемой задачи сформируем вектор входных параметров. Так как список витаминов состоит из 13 наименований, макроэлементов –

из 7, микроэлементов – из 4, а число классов – 4, то размерность входного вектора равна 28. Введем переменные Var 1 – Var 28 в диалоговом окне *Selekt input, output*, как непрерывные и категориальные, согласно указанному списку. Разбиение данных на обучающее, контрольное и тестовое множества осуществим с использованием опции *Intelligent Problem Solver*, которую выберем из раздела *Selekt analysis*. В этом окне на вкладке *Quick* установим в разделе *Networks tested* число тестируемых сетей, например, 10. Все остальные параметры на вкладке устанавливаются по умолчанию. Контроль алгоритма поиска подходящей сети осуществим в диалоговом окне *IPS Training In Progress* по информации о времени исполнения алгоритма, значениям ошибок на обучающем, контрольном и тестовом множествах, путем сравнения их между собой. Анализ осуществляем по десяти строкам информационного поля диалогового окна. В разделе *Profile* фиксируем тип сети (*SNN – RBF 28:28 – 56 – 4:1*), где присутствуют также параметры сети и ее производительность. Под производительностью в задачах многомерной регрессии понимается отношение стандартного отклонения ошибок сети к стандартному отклонению исходных данных (*SD – ratio*). Обычно для практического использования эта величина не должна превышать значения 0,2 на каждом из трёх подмножеств выборки. В нашем случае, задача минимизации ошибок не ставилась, поэтому мы выбрали вариант сконструированной сети, соответствующий приемлемой для практики производительности (0,1857).

Таким образом, последовательно поставлены и решены три задачи моделирования системообразующих процессов построения формулы сбалансированного питания в среде стандартных нейроэмуляторов *Statistika Neural Network*: а) сформировано обучающее множество признаков для четырех классов состояний субъекта; б) реализована процедура диагностики его состояния по совокупности входных признаков; в) найдена функциональная зависимость между управляющими факторами и состояниями субъекта. Последовательное применение этих процедур позволяет получить искомую нейросетевую модель формулы сбалансированного питания, структура которой в формате проведенного анализа имеет вид:

(SNN – Kohonen 24:24 – 48:1) → (SNN – MLP 53:53 – 27 – 4:1) → (SNN – RBF 28:28 – 56 – 4:1)

ВЫВОДЫ

1. Научная новизна предлагаемого решения состоит в обосновании возможности автоматизации поиска формулы сбалансированного питания и управлении динамикой состояния субъекта на основе моделей в среде *Satsoft* в формате модуля *Statistika Neural Network*.

2. Практическая значимость результатов данного исследования заключается в сокращении времени принятия решений в задачах классификации и прогнозирования за счет автоматизации этого процесса; в повышении объективности принятых решений за счет снижения влияния человеческого фактора.

3. Перспективным и полезным, на наш взгляд, является продолжение исследований в двух направлениях:

а) адаптация полученных результатов для зашумленного вектора входных данных, что позволит установить границы применимости полученного алгоритмического и программного инструментария в условиях высокой степени неопределенности;

б) выделение главных компонент в пространстве словаря признаков, что позволит снизить размерность входного вектора без существенной потери информативности.

Литература

1. Ренсли Д. Пища и пищевые добавки / Ренсли Д., Донелли Д., Рид Н. ; пер. с англ. Т.П. Мосоловой. – М. : Мир, 2004. – 312 с.
2. Спиричев В.Б. Обогащение пищевых продуктов витаминами и минеральными веществами / Спиричев В.Б., Шатнюк Л.Н., Позняковский В.М. – Новосибирск, 2004. – 548 с.
3. Морозов А.А. Новые информационные технологии в системах принятия решений / А.А. Морозов // Управляющие системы и машины. – 1993. – № 3. – С. 13-32.
4. Бышевский Л.Ш. Биохимия для врача / Л.Ш. Бышевский, О.А. Терсенов. – Екатеринбург : Уральский рабочий, 1994. – 384 с.
5. Методы оценки витаминной обеспеченности населения / [Спиричев В.Б., Коденцова В.М., Вржесинская О.А. и др.] // ГУ НИИ питания РАМН МЗ РФ. – М., 2001. – 68 с.
6. Хайкин С. Нейронные сети: полный курс / Хайкин С. ; пер. с англ. – [2-е изд.] – М. : Издательский дом «Вильямс», 2006. – 1104 с.
7. Ляхов А.Л. Проблема моделирования сложных социотехнических систем [Электронный ресурс] / А.Л. Ляхов, С.П. Алешин // V дистанционная научно-практическая конференция с международным участием. Системы поддержки принятия решений. Теория и практика. СППР'2009. – Киев : ИПММС НАН Украины, 2009. – С. 31- 34. – Режим доступа : <http://conference.immsp.kiev>.
8. Ляхов А.Л. Искусственная нейронная сеть как измерительный инструмент адекватности модели с адаптивным классом точности / А.Л. Ляхов, С.П. Алешин // IV научно-практическая конференция с международным участием «Математическое и имитационное моделирование систем. МОДС-2009». – Киев, 2009. – С. 116-119.

О.Л. Ляхов, С.П. Альошин

Нейромережна модель формули збалансованого харчування

Робота присвячена проблемі автоматизації прийняття рішень в побудові формули збалансованого харчування із застосуванням технологій штучного інтелекту. Запропоновано методику побудови нейромережної моделі базових процесів пошуку оптимального складу інгредієнтів. Побудовано моделі кластерного аналізу вхідних даних, класифікатора станів і апроксиматора багатовимірної функції. Запропонована методика дозволяє автоматизувати процес пошуку оптимального складу біологічно активних добавок та знизити ступінь суб'єктивізму у прийнятті рішень.

A.L. Lyakhov, S.P. Aleshin

Model of Neural Network of the Balanced Food

The work deals with the problem of automation of decision-making in the construction of a formula of balanced nutrition with the use of artificial intelligence technologies. The technique of constructing neural network model of basic processes of finding the optimal composition of ingredients. We construct a model cluster analysis of input data, the classifier states and approximators multidimensional function. The proposed method allows to automate the process of finding the optimum composition of dietary supplements and reduce the degree of subjectivity in the decision-making.

Статья поступила в редакцию 25.03.2010.