О.П. Солдатова, Д.И. Кривякин

# РЕШЕНИЕ ЗАДАЧИ ПРОГНОЗИРОВАНИЯ С ИСПОЛЬЗОВАНИЕМ СЕТЕЙ HRBF

(Самарский национальный исследовательский университет
имени академика С.П. Королёва)

Прогнозирование в общем случае означает предсказание состояния какого-либо объекта, процесса или явления в будущем. Различают такие виды прогнозов, как прогноз погоды, предсказание хода болезни, научно-технический прогноз, прогноз рыночных котировок и т.д. Одним из возможных решений задачи прогнозирования является использование искусственных нейронных сетей. Целью данной работы является изучение возможностей гипер радиально-базисных сетей (HRBF) при решении задачи прогнозирования и сравнение её эффективности по сравнению с обычной радиально-базисной сетью (RBF).

Сеть HRBF имеет структуру, схожую со структурой сети RBF. Она состоит из одного скрытого слоя, выполняющего нелинейное отображение входной последовательности, и выходного нейрона, выполняющего линейное суммирование сигналов, поступающих от нейронов скрытого слоя [1]. Основой сети HRBF так же является радиальная функция активации скрытых нейронов, в общем виде записываемая как:

$$\varphi(x) = \varphi(\|x - c_i\|_{Q_i}) = \exp\left[-(x - c_i)^T Q_i^T Q_i (x - c_i)\right] = \exp\left[\frac{1}{2}(x - c_i)^T C_i (x - c_i)\right] \quad (1),$$

где матрица $\frac{1}{2}C_i = Q_i^T Q_i$ играет роль скалярного коэффициента $\frac{1}{2\sigma_i^2}$ стандартной многомерной функции Гаусса, используемой в сети RBF и заданной выражением (2).

$$\varphi(x) = \varphi(\| x - c_i \|) = \exp\left(-\frac{\| x - c_i \|^2}{2\sigma_i^2}\right) \quad (2),$$

где x – входной вектор, i – номер нейрона скрытого слоя.

Матрица $Q$ – матрица весовых коэффициентов эвклидовой меры, которая имеет для сети HRBF следующий вид:

$$\|x\|_Q^2 = (Qx)^T (Qx) = x^T Q^T Qx \quad (3)$$

Масштабирующая матрица при $N$-мерном векторе $x$ представлена формулой 4:





$$Q = \begin{bmatrix} Q_{11} & Q_{12} \dots & Q_{1N} \\ Q_{21} & Q_{22} \dots & Q_{2N} \\ \dots & \dots \quad \dots & \dots \\ Q_{N1} & Q_{N2} \dots & Q_{NN} \end{bmatrix} \quad (4)$$

Элементы, лежащие на главной диагонали матрицы, используются в качестве масштабирующих коэффициентов, а элементы $Q_{ij}$ характеризуют корреляцию между $i$-м и $j$-м компонентами входного вектора.

Для обучения как сети RBF, так и сети HRBF, были использованы метод обратного распространения ошибки вместе с алгоритмом наискорейшего спуска, целью которых является минимизация ошибки работы сети и получения желаемого результата.

В рамках данной работы была разработана автоматизированная система прогнозирования, интерфейс которой представлен на рисунке 2. Для обучения и тестирования работы нейросети были взяты данные по энергопотреблению на железной дороге в период с 1990 по 2013гг. Обе нейронных сети имели следующие параметры: количество скрытых нейронов – 24, размерность прогнозного окна – 6, количество циклов обучения – 1500, коэффициент обучения – 0,064, коэффициент разброса (момент) – 0,03.

Результаты проведенных исследований показали большую точность прогнозирования сети HRBF по сравнению с классической радиально-базисной сетью. Так, при указанных выше параметрах сети среднеквадратичное отклонение прогнозирования для сети RBF составило 0,0282 [2], сети HRBF – 0,0245. При этом наличие коэффициентов корреляции в гипер радиально-базисной сети позволяет также проводить в дальнейшем детальные исследования влияния отдельных входных компонентов на другие компоненты и на выходной результат. В то же время, сеть RBF имеет более простую структуру, что значительно ускоряет процесс её обучения при сохранении приемлемой точности прогнозирования.

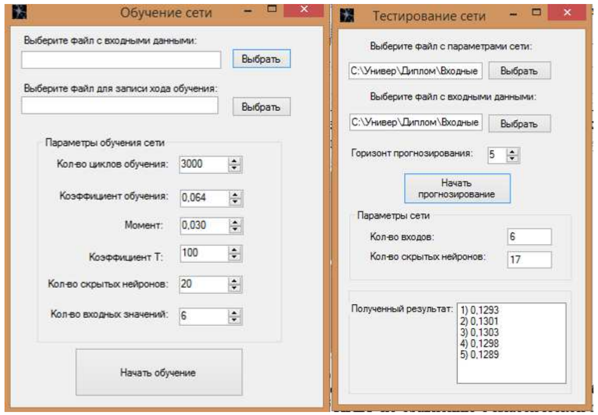


Рисунок 2 – Интерфейс системы

**Литература**

1. Осовский, С. Нейронные сети для обработки информации [Текст]/ С.Осовский. – М.: Финансы и статистика, 2002 – 344 с.
2. Кривякин Д.И. Решение задачи прогнозирования энергопотребления с помощью радиально-базисных сетей / Д.И. Кривякин // Искусственный интеллект: философия, методология, инновации: сборник трудов IX Всероссийской конференции студентов, аспирантов и молодых ученых. – М.: МИРЭА, 2015, с. 98-103.

О.П. Солдатова, А.Е. Мушин

# КЛАССИФИКАЦИЯ МУЗЫКАЛЬНЫХ КОМПОЗИЦИЙ С ИПОЛЬЗОВАНИЕМ ОДНОСЛОЙНОГО ПЕРСЕПТРОНА

(Самарский национальный исследовательский университет имени академика С.П. Королёва)

Человеческий мозг способен распознавать различные визуальные и звуковые образы, в том числе и музыкальные композиции. Музыкальные жанры – это высокоуровневые описания, создаваемые и используемые людьми для категоризации музыки. Они возникают в процессе сложного взаимодействия культур, исполнителей и используются для описания сходства между музыкантами или композициями, а также для организации музыкальных коллекций[1]. В музыкальной индустрии жанры используются как ключевой способ определения целевого рынка.

Для исследования звукового сигнала используется частотный анализ - разложение сложного звукового сигнала на ряд простых составляющих. Но прежде чем исследовать сигнал его необходимо преобразовать, для этого используется быстрое преобразование Фурье.

Частотный анализ звукового сигнала позволяет получить распределение амплитуд составляющих по частотам (амплитудно-частотные спектры) и распределение фаз составляющих по частотам (фазочастотные спектры) [2]. Так же звуковой сигнал представляется суммой коротких импульсов, характеризующихся временем появления и амплитудой. Таким образом, используются все частотно-амплитудные и временные характеристики сигнала [3,4].

Быстрым преобразованием Фурье (БПФ) называют набор алгоритмов, реализация которых приводит к существенному уменьшению вычислительной сложности дифференциального преобразования Фурье (ДПФ). Основная идея БПФ состоит в том, чтобы разбить исходный $N$-отсчетный сигнал $x(n)$ на два более коротких сигнала, ДПФ которых могут быть скомбинированы таким образом, чтобы получить ДПФ исходного $N$-отсчетного сигнала [3].

Так, если исходный $N$-отсчетный сигнал разбить на два $N/2$-отсчетных сигнала, то для вычисления ДПФ каждого из них потребуется около





$(N/2)^2$ комплексных умножений. Тогда для вычисления искомого $N$-отсчетного ДПФ потребуется порядка $2(N/2)^2 = N^2/2$ комплексных умножений, т.е. вдвое меньше по сравнению с прямым вычислением. Операцию разбиения можно повторить, вычисляя вместо $(N/2)$-отсчетного ДПФ два $(N/4)$-отсчетных ДПФ и сокращая тем самым объем вычислений еще в два раза. Выигрыш в два раза является приблизительным, поскольку не учитывается, каким образом из ДПФ меньшего размера образуется искомое $N$-отсчетное ДПФ[3].

В результате преобразования получается массив комплексных чисел, содержащий информацию об амплитудном и фазовом спектрах анализируемого сигнала. Спектры являются дискретными с шагом равным (частота дискретизации)/(количество отсчётов). То есть чем больше в сигнале отсчётов, тем более точное разрешение по частоте получается. Однако при постоянной частоте дискретизации увеличение числа отсчётов, приводит к увеличению анализируемого временного интервала, а поскольку в реальных музыкальных произведениях ноты имеют различную длительность звучания и могут быстро сменять друг друга, происходит их наложение друг на друга, поэтому амплитуда длительных нот «затмевает» собой амплитуду коротких нот [3].

Для распознавания и классификации музыкальных композиций в данной работе используется модель нейронной сети однослойного персептрон. Однослойный персептрон — это линейный алгоритм классификации, принцип работы которого основан на модели нервной клетки – нейронах [5].

Нейронные сети применяются для решения задач классификации или кластеризации многомерных данных. Основная идея, лежащая в основе нейронных сетей - это последовательное преобразование сигнала, параллельно работающими элементарными функциональными элементами – нейронами [5]. Нейрон состоит из трёх логических блоков: входы, функция активации, выход. На каждый вариант входа (вектор) функция активации нейрона вырабатывает определённый сигнал (выход - обычно скаляр), и передает его на входы другим нейронам сети. Подавая на входы некоторым нейронам сигналы извне, и отметив выходы части нейронов, как выходы сети в целом, мы получим систему, осуществляющую отображение $n \to k$, где $n$ - размерность входа (информации из вне), а $k$ - размерность выхода. Нейронные сети различаются функциями активации нейронов, внутренней архитектурой связей между нейронами и методами настройки (обучения).

Используемая архитектура однослойного персептрона, является классической реализации персептрона Розенблата. Здесь нейроны рецепторы принимают на вход действительные числа (обычно от 0 до 1), а ассоциативные нейроны используют сигмоидальную функцию преобразования [5].

Модель нейрона однослойного персептрона работает с действительными числами. Вот несколько важных свойств функции активации:

1. областью значений функции является интервал (0,1);
2. функция бесконечное число раз непрерывно дифференцируема;
3. её производная выражается только через неё саму: $f' = f(1 - f)$.