

ПРОГНОЗИРОВАНИЕ ОСТАТКОВ ДЕНЕЖНЫХ СРЕДСТВ НА ТЕКУЩИХ И ДЕПОЗИТНЫХ СЧЕТАХ КЛИЕНТОВ

Кириян Е.М., группа АСУ–01а

Руководитель доц. каф. АСУ Орлов Ю.К.

Ликвидность — один из основных и наиболее сложных факторов, определяющих финансовое состояние и надежность банка. Огромное влияние на банковскую ликвидность оказывает такая категория пассивов, как депозиты и текущие счета клиентов, о чем свидетельствует слишком высокий удельный вес таких пассивов в балансах украинских коммерческих банков. Очевидно, что данная категория банковских ресурсов как никакая другая связана с риском ликвидности, так как сроки изъятия средств с рассматриваемых счетов являются неопределенными по своей природе. Вместе с тем, такие пассивы — один из самых дешевых источников банковских ресурсов, и способствуют максимизации прибыли путём значительного уменьшения процентных затрат банка. [1]

Таким образом, проблема прогнозирования предполагаемого остатка средств на текущих и депозитных счетах занимает особое место в процессе управления банковской ликвидностью, даёт возможность, несмотря на высокую подвижность средств на таких счетах, определить постоянный гарантированный их остаток и использовать его в качестве стабильного кредитного ресурса. [2]

Рассмотрим постановку задачи. Наблюдаются величины $Y=Y(t)$ средневзвешенных остатков денежных средств на счетах клиентов в дискретные моменты времени (месяцы) $t_i = t_0 + i\Delta t$, $i = \overline{1, T}$, где t_0 — некоторый начальный момент времени, Δt — промежуток времени между наблюдениями, T — горизонт прогнозирования. Задача прогнозирования заключается в том, чтобы по известному участку временного ряда $\{t_i, Y(t_i)\}_{i=1}^T$ оценить будущие значения

величины Y на заданный период упреждения прогноза, учитывая набор влияющих на прогнозируемую величину факторов $X = (X_1(t), X_2(t), \dots, X_n(t))$.

Для построения модели поведения остатков денежных средств на депозитных счетах необходимо соответствующим образом описать её. Остаток на анализируемых счетах в связи с высокой мобильностью средств не постоянен и часто крайне изменчив. Числовое значение остатка на всех балансовых счетах данной группы представляет собой сумму остатков на некотором количестве счетов в соответствующий момент времени и является случайной величиной, непрерывной в интервале $(0; +\infty)$ [3]. Согласно с законом больших чисел, при некоторых достаточно широких условиях (попарная независимость случайных величин, равенство их математического ожидания, равномерная ограниченность дисперсий) суммарное поведение значительного количества случайных величин практически становится закономерностью.

Руководствуясь этими соображениями, в целях увеличения качества исходных данных для прогнозирования, а, следовательно, и улучшения качества самого прогноза необходимо произвести классификацию клиентов коммерческого банка в зависимости от параметров временного ряда, описывающего поведение остатков на каждом конкретном счете путём разбиения клиентов на группы по величине их математического ожидания, которое характеризует среднюю сумму средств, хранящихся на счете в анализируемый период времени. Затем каждая группа разбивается на подгруппы в зависимости от величины дисперсии. Прогнозирование предполагается осуществлять по каждой группе в отдельности, представляя общий результат суммой полученных прогнозов.

Выбор модели прогнозирования был обусловлен преимуществами аппарата нейронных сетей по сравнению с другими существующими методами. При этом на повышение эффективности обучения нейронной сети существенное влияние оказывает предобработка данных, основным принципом которой является увеличение информативности примеров.

Для решения поставленной задачи прогнозирования методами корреляционного анализа определяется набор влияющих на прогнозируемый показатель факторов. Затем входное пространство признаков должно быть оптимизировано на основании методики box-counting путём определения индивидуальной значимости (кросс-энтропии) для каждого входа. При необходимости восстанавливается пропущенная информация (путём замены пропущенных значений на среднее значение величины), устраняются аномальные выбросы, которые могут исказить результат обучения (путём превращения выбросов в пропущенные значения). Далее производится нормирование входных данных в интервале $[-1;1]$, а для достижения максимальной информационной насыщенности каждого из входных факторов в отдельности и их статистической независимости должна быть осуществлена декорреляция (“выбеливание”) входов [4].

Прогнозирующая система состоит из нескольких нейросетевых модулей, каждый из которых является многослойным персептроном и используется для исследования счетов определенной группы клиентов, т.е. обучения соотношений между вышеперечисленными экономическими факторами и величинами средневзвешенных ежемесячных остатков на счетах клиентов этой группы. Таким образом, входами каждого модуля являются выявленные на основании вышеописанных критериев и проведенных экспериментов факторы, сведения об остатках на определенной группе счетов за n предшествующих месяцев (а именно — их относительное изменение по отношению к предыдущему месяцу), а также сведения о сезонности, то есть данные о средневзвешенных ежемесячных остатках соответствующего периода предыдущего года. Выходом является прогнозируемое значение остатка денежных средств в планируемом месяце, получаемое как сумма прогнозов по каждой группе (рис. 1).

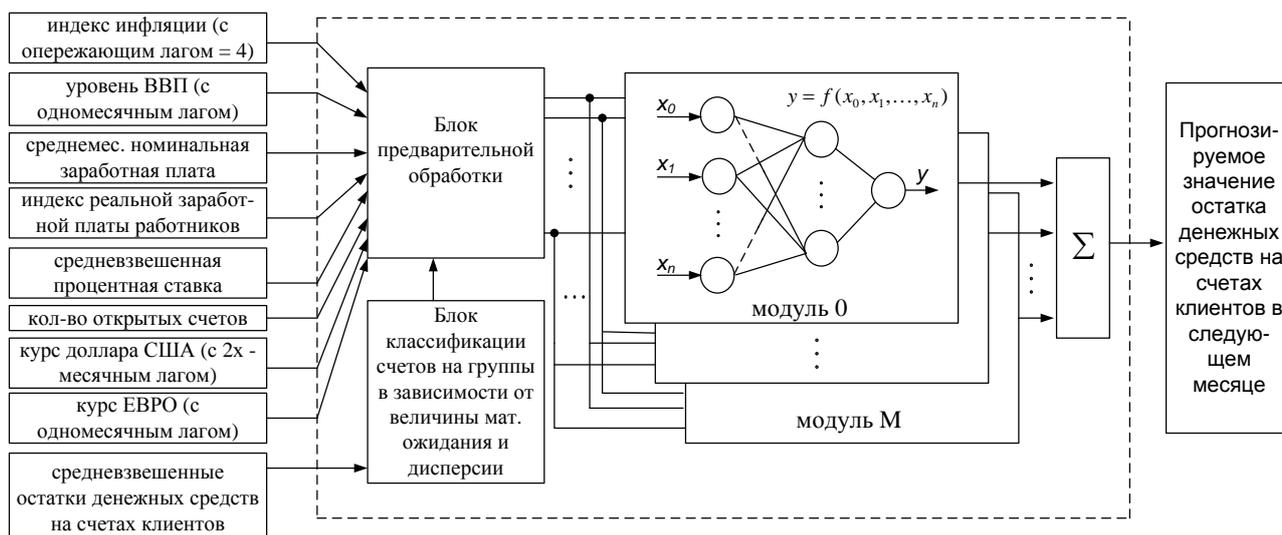


Рисунок 1 — Схема прогнозирования остатков денежных средств на заданной группе балансовых счетов

Для обучения сети используется алгоритм обратного распространения ошибки, который строится следующим образом:

1. Инициализировать весовые коэффициенты сети.

2. Подать на входы сети один из возможных образов и рассчитать значения выходов:

$$y_j^{(n)} = f\left(\sum_{i=0}^M y_i^{(n-1)} \cdot w_{ij}^{(n)}\right), \quad (1)$$

где M — число нейронов в слое $n-1$; $y_i^{(n-1)} = x_{ij}^{(n)}$ — i -ый вход нейрона j слоя n , $w_{ij}^{(n)}$ — вес от нейрона i слоя $n-1$ к нейрону j слоя n , $f(s)$ — сигмоид.

3. Рассчитать невязки нейронов для коррекции весовых коэффициентов по формулам:

$$\delta_j^{(n)} = \left[\sum_k \delta_k^{(n+1)} \cdot w_{jk}^{(n+1)} \right] \cdot \frac{dy_j}{ds_j} \quad \text{— для скрытых слоёв;} \quad (2)$$

$$\delta_l^{(N)} = (y_l^{(N)} - d_l) \cdot \frac{dy_l}{ds_l} \quad \text{— для выходного слоя.} \quad (3)$$

4. Рассчитать производную ошибки по весу между i -м нейроном слоя $n-1$ и j -м нейроном слоя n :

$$\frac{\partial E}{\partial w_{ij}} = \delta_j^{(n)} \cdot y_i^{(n-1)}. \quad (4)$$

5. Скорректировать все веса нейронной сети: $w_{ij}^{(n)}(t) = w_{ij}^{(n)}(t-1) + \Delta w_{ij}^{(n)}(t)$, где изменения весов $\Delta w^{(n)}$ слоя n определить согласно выбранному методу коррекции весовых коэффициентов.

6. Если поданы все входные образы, перейти к следующему шагу, иначе — возврат к шагу 2.

7. Рассчитать минимизируемую целевую функцию ошибки сети:

$$E(w) = \frac{1}{2} \sum_{i=1}^M \sum_{j=1}^P (y_{ij}^{(N)} - d_{ij})^2, \quad (5)$$

где y_{ij} — рассчитанное выходное состояние нейрона j выходного слоя N нейронной сети при подаче на ее входы i -го образа; d_{ij} — желаемое выходное состояние этого нейрона.

Если ошибка сети не превышает некоторый допустимый уровень ошибки ε , сеть обучена и может выполнять задачу прогнозирования, в противном случае — возврат к шагу 2 (подача на входы сети входных образов начинается сначала) [4].

Для коррекции весовых коэффициентов на основании экспериментальных исследований выбран алгоритм Resilient Propagation (RPROP), который использует знаки частных производных и индивидуальную для каждого веса величину шага обновления, адаптируемую в процессе обучения:

$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ \Delta_{ij}^{(t-1)}, & \frac{\partial E^{(t)}}{\partial w_{ij}} \frac{\partial E^{(t-1)}}{\partial w_{ij}} > 0 \\ \eta^- \Delta_{ij}^{(t-1)}, & \frac{\partial E^{(t)}}{\partial w_{ij}} \frac{\partial E^{(t-1)}}{\partial w_{ij}} < 0 \\ \Delta_{ij}^{(t-1)}, & \frac{\partial E^{(t)}}{\partial w_{ij}} \frac{\partial E^{(t-1)}}{\partial w_{ij}} = 0 \end{cases}, \quad \text{где } 0 < \eta^- < 1 < \eta^+. \quad (6)$$

Изменение веса производится по формуле:

$$\Delta w_{ij}^t = -\Delta_{ij}^t \operatorname{sign} \left(\frac{\partial E^{(t)}}{\partial w_{ij}} \right). \quad (7)$$

Начальная инициализация весов выполняется согласно методу Нгуена–Видроу, позволяющему значительно сократить количество итераций обучения за счет большей близости начальных значений к оптимальным. [5]

Выбор структуры нейронной сети основан на теореме Колмогорова, согласно которой для моделирования любого процесса достаточно нейронной сети с одним скрытым слоем с $2n+1$ нейронами в этом слое, однако предполагается исследовать с точки зрения повышения качества решения задачи целесообразность использования нейроэволюционного алгоритма.

Владение более совершенными методами анализа и прогнозирования остатков на депозитных и текущих счетах клиентов поможет банку более эффективно и рационально распределять свои усилия и средства на их привлечение, а также планировать использование этих средств в качестве стабильного ресурса для кредитования (в том числе межбанковских кредитов), вложения в ценные бумаги и т.д., максимизировать банковскую прибыль путём инвестирования приравненных к собственным средств в прибыльные активы без риска ликвидности.

Перечень ссылок

1. Д.Олійник. Управління ліквідністю комерційного банку на основі оптимального використання залишків тимчасово вільних коштів на рахунках клієнтів // Банківська справа, 2001. — №2. — С. 31–34, 41.
2. Н.Костіна, П.Черняхівська. Прогнозування надходження готівкових коштів до установи комерційного банку // Банківська справа, 2000. — №1. — С. 17–24.
3. Л.Сергєєва, А.Позднякова. Комплексний аналіз залишків на рахунках клієнтів комерційного банку // Банківська справа, 2002. — №3. — С. 46–49.
4. Ежов А.А., Шумский С.А. Нейрокомпьютинг и его применения в экономике и бизнесе (серия "Учебники экономико-аналитического института МИФИ"/ Под ред. проф. В.В. Харитонова). — М.: МИФИ, 1998. — 224 с.
5. Nguyen, D., and B. Widrow, "Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights," Proceedings of the International Joint Conference on Neural Networks, vol 3, pp. 21–26, 1990.